

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
E INFORMÁTICA INDUSTRIAL

DANIEL PRADO DE CAMPOS

CLASSIFICAÇÃO DE SINAIS ELETROMIOGRÁFICOS DO  
MÚSCULO MASSETER DE BOVINOS BASEADA EM  
DICIONÁRIOS PARA RECONHECIMENTO DE PADRÕES  
INGESTIVOS

TESE

CURITIBA

2019

DANIEL PRADO DE CAMPOS

**CLASSIFICAÇÃO DE SINAIS ELETROMIOGRÁFICOS DO  
MÚSCULO MASSETER DE BOVINOS BASEADA EM  
DICIONÁRIOS PARA RECONHECIMENTO DE PADRÕES  
INGESTIVOS**

Tese apresentada ao Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Doutor em Ciências” – Área de Concentração: Informática Industrial.

Orientador: Paulo José Abatti

Coorientador: Fábio Luiz Bertotti

**CURITIBA**

**2019**

Dados Internacionais de Catalogação na Publicação

---

Campos, Daniel Prado de

Classificação de sinais eletromiográficos do músculo masseter de bovinos baseada em dicionários para reconhecimento de padrões ingestivos [recurso eletrônico] / Daniel Prado de Campos.-- 2019.

1 arquivo texto (113 f.) : PDF ; 16,9 MB.

Modo de acesso: World Wide Web.

Título extraído da tela de título (visualizado em 30 out. 2019).

Texto em português com resumo em inglês

Tese (Doutorado) - Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Curitiba, 2019

Bibliografia: f. 79-90

1. Engenharia elétrica - Teses. 2. Processamento de sinais. 3. Reconhecimento de padrões. 4. Bovino - Criação - Automação. 5. Bovinos - Alimentação - Simulação por computador. 6. Nutrição animal. 7. Animais - Proteção. 8. Eletromiografia. I. Abatti, Paulo José. II. Bertotti, Fábio Luiz. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. IV. Título.

CDD: Ed. 23 – 621.3

---

Biblioteca Central da UTFPR, Câmpus Curitiba  
Bibliotecário: Adriano Lopes CRB-9/1429

## TERMO DE APROVAÇÃO DE TESE Nº 203

A Tese de Doutorado intitulada “**Classificação de sinais eletromiográficos do músculo masseter de bovinos baseada em dicionários para reconhecimento de padrões ingestivos**”, defendida em sessão pública pelo(a) candidato(a) **Daniel Prado de Campos**, no dia **29 de outubro de 2019**, foi julgada para a obtenção do título de Doutor em Ciências, área de concentração **Engenharia Biomédica**, e aprovada em sua forma final, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial.

### BANCA EXAMINADORA:

Prof. Dr. João Antônio Palma Setti - Presidente – (UTFPR)

Prof. Dr. André Eugênio Lazzaretti – (UTFPR)

Prof. Dr. Marcos Martinez do Vale – (UFPR)

Prof. Dr. Alceu de Souza Britto Jr– (PUC-PR)

A via original deste documento encontra-se arquivada na Secretaria do Programa, contendo a assinatura da Coordenação após a entrega da versão corrigida do trabalho.

Curitiba, 29 de outubro de 2019.

---

Assinatura e Carimbo do(a) Coordenador(a) do Programa

Ao devir.

## AGRADECIMENTOS

Agradeço a todos os indivíduos que me auxiliaram direta ou indiretamente, pessoal ou tecnicamente, proposital ou acidentalmente. No entanto agradeço especialmente àqueles que foram minha égide e meu arrimo.

"Não é que temos uma vida curta, mas é que desperdiçamos muito dela. A vida, se bem empregada, é suficientemente longa e nos foi dada com muita generosidade para a realização de importantes tarefas. Ao contrário, se desperdiçada no luxo e na indiferença, se nenhuma obra é concretizada, por fim, se não se respeita nenhum valor, não realizamos aquilo que deveríamos realizar, sentimos que ela realmente se esvai."

Lucio Anneo Seneca

*De Brevitate Vitae*

## RESUMO

CAMPOS, Daniel Prado. Classificação de sinais eletromiográficos do músculo masseter de bovinos baseada em dicionários para reconhecimento de padrões ingestivos. 113 f. Tese – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2019.

Esse trabalho apresenta uma proposta de um novo método de reconhecimento de padrões em sinais de eletromiografia de superfície do músculo masseter de vacas leiteiras para classificação de padrões de ingestão e ruminação, bem como a definição de uma metodologia de segmentação desse sinal. O método, chamado de Aprendizado de Dicionário por Discriminante de Fisher (FDDL), é baseado no treinamento de dicionários específicos à classe, o qual é constituído de uma matriz composta de protótipos de sinais. Os dicionários definem um vetor esparsos que codifica o sinal com a finalidade de reconstrução. As informações de erro de reconstrução para cada dicionário são usadas como métricas para classificação, dessa forma dispensando etapas de extração de característica. Resultados em bovinos com 2000 exemplos de mastigação e validação cruzada mostraram uma classificação com desempenho significativamente superior ( $p < 0,05$ ) em relação aos métodos presentes na literatura, apresentando taxa de acerto média de 90%. O método se demonstrou robusto à presença de ruídos, com ganho na taxa de acerto de 2,45% com adição de ruídos severos (0 dB) no treino e no teste e 14,75% com adição apenas no teste, sendo superior à todos os métodos na faixa de 0-20 dB. A continuação do trabalho deve avaliar a capacidade de implementação do método em tempo-real e expandir a classificação para outros padrões ingestivos, como identificação da altura de pasto.

**Palavras-chave:** Processamento de sinais. Extração de Características. Aprendizado de Dicionário. FDDL. sEMG. Reconhecimento de Padrões. Nutrição animal. Bem-estar animal.



## ABSTRACT

CAMPOS, Daniel Prado. Dictionary-based Classification of Electromyographic signals of the masseter muscle of cows to recognize ingestive patterns. 113 f. Tese – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2019.

This work presents a proposal for a new pattern recognition method of surface electromyography signals of cows masseter muscle for classification of ingestion and rumination patterns, as well as the definition of a segmentation methodology for this signal. The method, called Fisher Discriminant Dictionary Learning (FDDL), is based on the training of class-specific dictionaries, which is a matrix composed of signal prototypes. Dictionaries define a sparse vector that encodes the signal for the purpose of signal reconstruction. The reconstruction error information from each dictionary is used as a metric for classification, thus eliminating the feature extraction step. Results in cows with 2000 examples of chewing and cross-validation showed a significantly higher performance rating ( $p < 0.05$ ) in relation to the current methods found in the literature, with an average accuracy of 90 %. The method proved to be robust in the presence of noise, with a performance gain of 2.45% with addition of severe noise (0 dB) in the training and test and 14.75% with addition in the test only, being superior to all methods in the range of 0-20 dB. Further works should evaluate the method's ability to be implemented for real-time operation and expand the classification to other ingestive patterns, such as identification of pasture height.

**Keywords:** Signal processing. Feature extraction. Dictionary Learning. FDDL. sEMG. Pattern Recognition. Animal Nutrition. Animal welfare.

## LISTA DE FIGURAS

FIGURA 1 –	Áreas de pastagens e milhões de hectares e produtividade em @/ha/ano entre os anos de 1990 e 2018. ....	19
FIGURA 2 –	Transdutor opto-eleto-mecânico de movimentos mastigatórios. Sistema de medição e registro (a) e detalhe do pulsador eletromecânico (b). ....	25
FIGURA 3 –	Transdutor eletro-mecânico de movimentos mastigatórios. Tubo com contatos montado em cabresto (a) e registro da taxa de mastigação por minuto (b). ....	25
FIGURA 4 –	Sensor de deformação utilizando tubo preenchido com grânulos de carbono. Sensor a esquerda e sistema DAQ a direita (a) e sistema completo no animal (b). ....	27
FIGURA 5 –	Sensor de deformação utilizando extensômetro. Montagem do transdutor (a) e sistema completo no animal (b). ....	28
FIGURA 6 –	Sistema de aquisição de sinais bioacústicos. Microfone lateral (a) e microfone na parte anterior da cabeça do animal (b). ....	29
FIGURA 7 –	Sistema de aquisição de dados e posicionamento do biossensor baseado em redes de Bragg em fibra óptica. Montagem do sensor (a) e instrumentação e aquisição de sinais (b). ....	32
FIGURA 8 –	Instrumento de medição Myo-Sensor MS15 desenvolvido pela empresa Bitsz Engineering. Um módulo (a) faz aquisição de sEMG por eletrodos metálicos secos (b) conectados por meio de cabo. O módulo transmite os dados via radiofrequência para uma base receptora (c). .	33
FIGURA 9 –	Resultados obtidos dos primeiros experimento de investigação do comportamento ingestivo em ruminantes a partir de EMG: contagem automática de movimentos mastigatórios (a) e análise de características do sinal em diferentes cenários (b). ....	34
FIGURA 10–	Resultados mais recentes da investigação do comportamento ingestivo em ruminantes a partir de EMG: estimação de consumo de curto-prazo (a) e classificação de tipos de pasto e ruminação (b). ....	35
FIGURA 11 –	Modelo matemático e fisiológico da composição de um sinal de EMG.	40
FIGURA 12 –	Representação esparsa de sinais. ....	41
FIGURA 13 –	Interpretação geométrica do termo de fidelidade de discriminação $r(\mathbf{A}, \mathbf{D}, \mathbf{X})$ (a) e as componentes de espalhamento intra e entre classes do termo de discriminação $f(\mathbf{X})$ (b). ....	45
FIGURA 14 –	Diagrama em blocos do processamento de sinais. ....	48
FIGURA 15–	Localização dos eletrodos de sEMG no bovino. Dois eletrodos bipolares são posicionados sobre a pele, acima da região do músculo masseter e um terceiro eletrodo é posicionado em uma região de baixa atividade eletrotônica. ....	49
FIGURA 16 –	Diagrama simplificado do sistema embarcado utilizado na aquisição do sistema de EMG do músculo masseter. ....	51

FIGURA 17 –	Processo de filtragem do sinal bruto de EMG. ....	52
FIGURA 18–	Sinal eletromiográfico durante 90 segundos de consumo (a) e ruminção (b) e detalhamento de uma mastigação durante 3 segundos de cada atividade (c,d). ....	53
FIGURA 19–	Processo do método de segmentação (a) e avaliação (b). O sinal é retificado e suavizado por média móvel. O limiar é aplicado para identificar o período de contração muscular. Se o período ( $T$ ) é maior que um valor crítico ( $W_{crit}$ ), o segmento é armazenado. A avaliação é baseada na comparação entre os períodos detectados pelo método proposto e identificados visualmente. ....	55
FIGURA 20–	Metodologia de classificação usando o algoritmo FDDL. Um conjunto de treino é usado para aprender um dicionário e um matriz de coeficientes de representação para cada classe (a). O sinal é atribuído para a classe cujo dicionário apresenta menor erro de reconstrução e maior similaridade entre os vetores de representação (b). ....	60
FIGURA 21 –	Histograma normalizado como função densidade de probabilidade do período dos segmentos extraídos pela técnica FLPCS. ....	63
FIGURA 22 –	Histograma normalizado como função densidade de probabilidade da duração dos segmentos extraídos pela técnica DTOS. ....	64
FIGURA 23 –	Erro do método de segmentação automática (DTOS) em função do fator de limiar ( $k$ ) e janela de suavização. O gráfico interno mostra o menor erro encontrado para cada janela e o valor de $k$ respectivo. ....	65
FIGURA 24 –	GMM do período do sinal de EMG segmentado por inspeção visual e pelo método DTOS (a). Divergência de Kullback-Leibler (KLD) entre os modelos (b). ....	66
FIGURA 25–	Histograma e GMM do período mastigatório obtido a partir de inspeção visual (a) e pelo método de segmentação DTOS (b). ....	67
FIGURA 26 –	Fragmento de sinal de sEMG durante ingestão. O série-temporal bifásica é composta por um sinal de menor amplitude com duração de menos de 200 ms seguido por um sinal de maior amplitude com duração menor que 500 ms. O intervalo entre as duas fases é sempre maior que 200 ms. ....	69
FIGURA 27 –	Resultados de classificação para características individuais (a) e em conjuntos (b). Barra à esquerda representa características extraídas de janela fixa e à direita de janela variável. Asteriscos (*) indicam diferença significativa ( $p < 0,05$ ). ....	70
FIGURA 28 –	Procedimento de classificação de um sinal de EMG usando FDDL. Um segmento de sinal de EMG (a) é representado como um vetor de esparso (b) o qual é usado para obter um termo de erro (c) que define a qual classe o exemplo pertence (d). ....	71
FIGURA 29–	Resultados do reconhecimento de padrão eletromiográfico usando o método proposto. Taxa de acertos média e desvio padrão usando FDDL com diferentes tamanhos de dicionário (a). Diagrama de caixas dos melhores resultados obtidos por extração não-supervisionada de características e FDDL (b). Os asteriscos indicam diferença significativa ( $p < 0,05$ ) em relação ao método proposto. ....	71
FIGURA 30 –	Matriz de confusão da classificação obtido pelo método FDDL (a)	

	e pelo conjunto de características MS2 combinado com o classificador LDA (b). . . . .	72
FIGURA 31	– Desempenho de classificação dos quatro conjuntos de características e FDDL com ruído adicionado aos dados de EMG no treino e no teste. . . . .	74
FIGURA 32	– Desempenho de classificação dos quatro conjuntos de características e FDDL com ruído adicionado aos dados de EMG no teste. . . . .	75
FIGURA 33	– Detalhe anatômico do músculo masseter de um bovino. . . . .	93
FIGURA 34	– Métodos de segmentação . . . . .	96
FIGURA 35	– Extração de características por meio de treinamento de dicionário (kSVD), codificação esparsa (OMP) e Pooling. . . . .	99
FIGURA 36	– Fluxograma de validação e teste da técnica de extração de características por kSVD. . . . .	100
FIGURA 37	– Gráfico em barras da taxa de acertos dos classificadores para diferentes métodos de segmentação. Os bigodes nas caixas representam o desvio padrão. . . . .	101
FIGURA 38	– Representação esparsa de um sinal de sEMG. . . . .	102
FIGURA 39	– Erro quadrático médio da reconstrução dos segmentos de sinais de sEMG do conjunto de validação. . . . .	103
FIGURA 40	– Dispersões dos resultados de classificação por kNN usando o máximo e a média do vetor esparsa variando os parâmetros de esparsidade e dimensão. . . . .	104
FIGURA 41	– Dispersões dos resultados de classificação por kNN usando características individualmente. . . . .	104
FIGURA 42	– Diagramas de caixas e bigodes da dispersão das características escolhidas para classificação. . . . .	105
FIGURA 43	– Dispersão em plano bidimensional entre pares de características do sinal bruto (SSI e WL) e vetor esparsa (máximo e média). . . . .	106
FIGURA 44	– Diagrama de barras dos resultados da identificação de padrões de ruminção e consumo de silagem para diferentes combinações de características e técnicas de classificação. . . . .	107
FIGURA 45	– Comportamento da classificação de uma característica com variação de média e desvio padrão. O desempenho do classificador treinado para um conjunto de dados (a) é dramaticamente afetado com deslocamento da média das características (b), porém pode apresentar uma melhora anormal de desempenho caso a variância aumente (c). . . . .	109

## LISTA DE SIGLAS

FDDL	Aprendizado de Dicionário por Discriminante de Fisher (do inglês <i>Fisher Discrimination Dictionary Learning</i> )
PLF	Pecuária de Precisão (do inglês <i>Precision Livestock Farming</i> )
sEMG	Eletromiografia de superfície (do inglês <i>Surface Electromyography</i> )
EMG	Eletromiografia (do inglês <i>Electromyography</i> )
PIB	Produto Interno Bruto
Ag/AgCl	Prata/Cloreto de Prata
IMU	Unidades de Medida Inercial (do inglês <i>Inertial Measurement Units</i> )
CNN	Redes Neurais Convolucionais (do inglês <i>Convolutional Neural Networks</i> )
SRC	Reconhecimento de Padrões Baseados em Representações Esparsas (do inglês <i>Sparse Representation-Based Classification</i> )
IGER	<i>Institute of Grassland and Environmental Research</i>
CMS	Consumo de Matéria Seca
DAQ	Aquisição de Dados (do inglês <i>Data Acquisition</i> )
FBG	Redes de Bragg em Fibra Óptica (do inglês <i>Fiber Bragg Grating</i> ).
UV	Ultravioleta
UTFPR	Universidade Tecnológica Federal do Paraná
IAPAR	Instituto Agrônômico do Paraná
MU	Unidade Motora (do inglês <i>Motor Unit</i> )
MFAP	Potencial de Ação da Fibra Muscular (do inglês <i>Muscle Fiber Action Potencial</i> )
MUAP	Potencial de Ação da Unidade Motora (do inglês <i>Muscle Unit Action Potencial</i> )
MUAPT	Trem de Potenciais de Ação da Unidade Motora (do inglês <i>MUAP Train</i> )
CEUA	Comitê de Ética de Uso Animal
SENIAM	EMG de Superfície para Avaliação Não-Invasiva de Músculos (do inglês <i>Surface EMG for a Non-Invasive Assessment of Muscles</i> )
AFE	Interface Analógica (do inglês <i>Analog front-end</i> )
SD	<i>Secure Digital</i>
CPU	Unidade de Processamento Central (do inglês <i>Central processing unit</i> )
SRAM	Memória de Acesso Aleatório Estática (do inglês <i>Static random-access memory</i> )
FAT32	<i>File Allocation Table 32-bits</i>
SPI	Interface Serial Periférica (do inglês <i>Serial Peripheral Interface</i> )
PGA	Amplificador de Ganho Programável (do inglês <i>Programmable-gain amplifier</i> )
CMRR	Razão de Rejeição de Modo Comum (do inglês <i>Common-mode rejection ratio</i> )
ADC	Conversor Analógico-digital (do inglês <i>Analog-to-digital converter</i> )
RDL	Condicionador de Referência (do inglês <i>Right Leg Drive</i> )
IIR	Resposta Infinita ao Impulso, do inglês <i>Infinite Impulse Response</i>
HMM	Modelos Ocultos de Markov (do inglês <i>Hidden Markov Model</i> )
DTOS	Segmentação por Limiar Duplo (do inglês <i>Double Threshold Onset Segmentation</i> )

VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
FP	Falso Positivo
FN	Falso Negativo
TFN	Taxa de Falsos Negativos
TFP	Taxa de Falsos Positivos
TVP	Taxa de Verdadeiros Positivos
TVN	Taxa de Verdadeiros Negativos
PDF	Função de Densidade de Probabilidade (do inglês <i>Probability Density Function</i> )
GMM	Modelo de Mistura Gaussiana (do inglês <i>Gaussian Mixture Models</i> )
KLD	Divergência de Kullback-Leibler (do inglês <i>Kullback–Leibler divergence</i> )
MAV	Valor Médio Absoluto (do inglês <i>Mean Absolute Value</i> )
IAV	Integral do Valor Absoluto (do inglês <i>Integral of Absolute Value</i> )
RMS	Média Quadrática (do inglês <i>Root Mean Square</i> )
VAR	Variância
WL	Comprimento da Forma de onda (do inglês <i>Waveform Length</i> )
DASDV	Diferença Absoluta do Valor de Desvio Padrão (do inglês <i>Absolute Standard Deviation Value</i> )
MSR	Valor Médio da Raíz Quadrada (do inglês <i>Mean Value of the Square Root</i> )
LS	Escala-L (do inglês <i>L-Scale</i> )
WAMP	Amplitude Willison (do inglês <i>Willison Amplitude</i> )
SSC	Mudança do Sinal de Inclinação (do inglês <i>Slope Sign Change</i> )
ZC	Cruzamento por Zero (do inglês <i>Zero Crossing</i> )
MFL	Máximo Comprimento Fractal (do inglês <i>Maximum Fractal Length</i> )
AR	Coefficientes Autorregressivos (do inglês <i>Auto-regressive Coefficients</i> )
LDA	Análise de Discriminantes Lineares (do inglês <i>Linear Discriminat Analysis</i> )
SVM	Máquinas de Vetores de Suporte (do inglês <i>Support Vector Machines</i> )

## SUMÁRIO

<b>1 INTRODUÇÃO</b>	<b>16</b>
1.1 MOTIVAÇÃO	18
1.2 OBJETIVOS	22
1.2.1 Objetivo Geral	22
1.2.2 Objetivos Específicos	22
1.3 ESTRUTURA DO TRABALHO	23
<b>2 REVISÃO DE LITERATURA</b>	<b>24</b>
2.1 CHAVES DE CONTATO	24
2.2 MÉTODOS EXTENSIOMÉTRICOS E BAROMÉTRICOS	26
2.3 MÉTODOS ACÚSTICOS	28
2.4 MÉTODOS ACELEROMÉTRICOS	30
2.5 REDES DE BRAGG EM FIBRA ÓPTICA	31
2.6 MÉTODOS ELETROMIOGRÁFICOS	32
2.7 TRABALHOS ANTECESSORES	33
2.8 CONSIDERAÇÕES	36
<b>3 FUNDAMENTAÇÃO TEÓRICA</b>	<b>37</b>
3.1 ELETROMIOGRAFIA (EMG)	37
3.2 REPRESENTAÇÃO ESPARSA	39
3.3 CLASSIFICAÇÃO BASEADA EM APRENDIZADO DE DICIONÁRIO	41
3.4 CONCLUSÃO	47
<b>4 METODOLOGIA</b>	<b>48</b>
4.1 PROTOCOLO EXPERIMENTAL	48
4.2 AQUISIÇÃO DE EMG	50
4.3 PRÉ-PROCESSAMENTO	51
4.4 SEGMENTAÇÃO	54
4.5 EXTRAÇÃO DE CARACTERÍSTICAS	57
4.6 CLASSIFICAÇÃO	58
4.7 CONCLUSÃO	61
<b>5 RESULTADOS E DISCUSSÃO</b>	<b>62</b>
5.1 ANÁLISE QUALITATIVA	62
5.2 MÉTODO DE SEGMENTAÇÃO	63
5.3 CLASSIFICAÇÃO	68
<b>6 CONCLUSÃO</b>	<b>77</b>
<b>REFERÊNCIAS</b>	<b>79</b>
<b>Apêndice A – CODIFICAÇÃO ESPARSA</b>	<b>91</b>
<b>Apêndice B – ANATOMIA DO MÚSCULO MASSETER</b>	<b>93</b>
<b>Apêndice C – EXTRAÇÃO DE CARACTERÍSTICAS USANDO KSVD</b>	<b>94</b>
C.1 METODOLOGIA	94
C.2 SEGMENTAÇÃO	95
C.3 EXTRAÇÃO DE CARACTERÍSTICAS E CLASSIFICAÇÃO	98
C.3.1 Efeito da segmentação na classificação	100

C.4 K-SVD .....	102
C.4.1 Validação .....	102
C.4.2 Teste .....	105
C.5 CONCLUSÃO .....	107
<b>Apêndice D – NÃO-MONOTONICIDADE DO ERRO .....</b>	<b>109</b>
<b>Anexo A – PARECER DA COMISSÃO DE ÉTICA NO USO ANIMAL .....</b>	<b>111</b>



## 1 INTRODUÇÃO

A Pecuária de Precisão (PLF) é uma combinação de ferramentas e métodos de medição de variáveis fisiológicas de animais de fazenda com alta precisão (VIRGILIO et al., 2018). A PLF emergiu da crescente demanda por produtos de origem animal junto com a necessidade de informar aos produtores sobre a saúde, bem-estar, produtividade e necessidade de seus animais (NORTON; BERCKMANS, 2018). Ainda, alertas gerados por sensores possibilitam que os produtores tratem necessidades individuais dos animais que precisam de atenção especial (HALACHMI et al., 2019). Dentro de uma ampla gama de variáveis que podem ser medidas, o consumo e a ruminação são dois importantes parâmetros. Como o consumo é um dos parâmetros mais custosos e importantes na produção agropecuária, deve ser observado constantemente e ajustado para atender as necessidades dos animais. A ruminação é um claro indicador de bem-estar, visto que redução do tempo de ruminação pode indicar estresse, ansiedade e doenças (TULLO et al., 2019).

Monitorar o comportamento ingestivo individual de animais é quase equivalente à monitorar a alimentação, ruminação e ócio, os quais cobrem 90 a 95% da atividade diária de animais ruminantes. Diversos sensores têm sido desenvolvidos para esse propósito, como chaves de contato, sensores de pressão, sensores acústicos, sensores inerciais e sensores eletromiográficos (ANDRIAMANDROSO A. L. H.; LEBEAU., 2016; GONZÁLEZ et al., 2018; HALACHMI et al., 2019). A Eletromiografia de superfície (sEMG) é o registro de potenciais evocados pelo músculo ao longo do tempo, carregando informação da ativação muscular. Essa técnica tem sido usada para diversas aplicações na investigação da biomecânica animal (VALENTIN; ZSOLDOS, 2016) e é promissora no estudo do comportamento ingestivo devido sua habilidade de detectar movimentos mastigatórios individualmente (BÜCHEL; SUNDRUM, 2014) e distinguir o tipo de alimento sendo ingerido (CAMPOS et al., 2018).

Obter informações do comportamento ingestivo em animais ruminantes pela resposta eletromiográfica é uma tarefa relativamente difícil quando comparado com

indivíduos humanos, já que não há controle dos movimentos executados pelo animal, e dessa forma, experimentos com tempo controlado não são possíveis. Os movimentos mastigatórios são normalmente rápidos (cerca de um movimento por segundo) e frequentemente contém movimentos anômalos (não-ingestivos) que se misturam aos sinais relativos à atividades mastigatórias. Assim, processar os dados utilizando técnicas de janelamento com passos fixos ao longo da série temporal, comumente usado em processamento de sinais eletromiográficos (PHINYOMARK et al., 2009), pode levar a erros. Isso posto, a segmentação do sinal deve ser seletiva apenas aos sinais relativos aos movimentos mastigatórios com a precisão de um ciclo mandibular.

Com relação ao reconhecimento de padrões ingestivos, a resposta eletromiográfica de músculos mastigatórios tem um potencial de acessar diretamente informação da ingestão. O processamento tradicional de sinais eletromiográficos é geralmente baseada na extração de características, redução de dimensionalidade e classificação (CHOWDHURY et al., 2013). A combinação ótima de conjuntos de características e classificador tem sido extensivamente estudada e reportada na literatura (IQBAL et al., 2018). Todavia, a performance da classificação pode ser substancialmente degradada quando novas amostras de dados desviam do conjunto de treinamento (Betthausen et al., 2018). Ainda, essas características extraídas manualmente (*hand-crafted features*) podem negligenciar informação (DING et al., 2018). Alternativamente, classificadores baseados em representação esparsa são robustos, especialmente quando o número de canais de Eletromiografia (EMG) são reduzidos, e não necessitam de uma etapa de seleção de um conjunto ótimo de características e classificador para cada aplicação (Betthausen et al., 2018; GENG et al., 2018).

Nesse contexto, o objetivo desse trabalho é identificar eventos mastigatórios e classificá-los como ingestão ou ruminância a partir de medidas de eletromiografia de superfície do músculo masseter. A principal hipótese é que técnicas de classificação baseadas em aprendizado de dicionário são uma alternativa robusta e viável para as técnicas atuais de extração de características e classificação de sinais de sEMG. Na abordagem proposta, o sinal é classificado pelo erro de reconstrução e informações da codificação esparsa obtidas por dicionários específicos à cada classe. Assim, este trabalho é uma pesquisa orientada à aplicação na investigação do comportamento ingestivo em animais ruminantes, onde é avaliada uma técnica recente de processamento de sinais baseada em aprendizado de dicionário. Até onde se conhece, essa abordagem ainda é pouco explorada e relatada na literatura da área de processamento de sinais de sEMG, sendo assim a principal contribuição do trabalho.

De maneira secundária, é definida uma metodologia de segmentação do sinal capaz de atingir a precisão de identificar um movimento mastigatório, visto que esse procedimento é geralmente manual ou apresenta carência de critério.

## 1.1 MOTIVAÇÃO


Entre os animais de corte, os ruminantes destacam-se em virtude de seu importante papel na produção de alimentos devido sua capacidade de transformação gastrintestinal de compostos vegetais, como celulose e hemicelulose, em alimentos como carne e leite (WILLIAMS et al., 2011).

O processo de modernização da agropecuária é recente, possui seu marco entre 1960 e 1970, período que ficou conhecido como a Revolução Verde. A necessidade de expandir a produção de alimentos, até então um recurso limitado em países menos desenvolvidos, fez com que rapidamente se difundissem tecnologias agrícolas. No Brasil, a revolução aconteceu entre os anos de 1970 e 1985, quando a produção de alimentos básicos e exportação cresceram significativamente. A explosão na produção mundial de alimentos e a globalização das exportações, resolveram uma parte do problema da fome mundial ao aumentar a produção líquida de alimentos (OCTAVIANO, 2010).

Em 2018, o Produto Interno Bruto (PIB) brasileiro atingiu R\$ 6,83 trilhões em que 8,7% corresponde a participação da pecuária de corte. O Brasil é dono do maior rebanho comercial do mundo e lidera as exportações com um quinto da carne comercializada internacionalmente (ABIEC, 2019). Em 2017, o Brasil exportou 1,53 milhões de toneladas de carne bovina e se consolidou o maior fornecedor mundial com um rebanho de 171 milhões de bovinos. Constatou-se ainda o aumento da demanda de produtos derivados do leite, estimulando o crescimento da produção leiteira. A produção nacional de leite foi de 33,1 bilhões de litros em 2017 com 38% proveniente da região Sul (RENTERO, 2018). Além disso, o Brasil é o quarto maior exportador de carne suína em que a região sul possui 53,8% dos 39,2 milhões de suínos em 2017. O rebanho bovino do país cresceu 12%. Houve redução de 11% das áreas de pastagens indicando aumento de produtividade (ABIEC, 2019). Em síntese, a produção de bovinos sofreu crescimento significativo nos últimos anos, mesmo tendo redução das áreas de pastagem como mostra o gráfico da Figura 1.

O Paraná ficou em 1º lugar no ranking de carne de frango com cerca de 347 milhões de aves que corresponde a 23% da produção nacional, 3º de carne suína, 8º de

**Figura 1: Áreas de pastagens e milhões de hectares e produtividade em @/ha/ano entre os anos de 1990 e 2018.**



Fonte: ABIEC (2019)

carne bovina e 3° de lácteos (IBGE, 2017).

O Brasil, e mais especificamente o Paraná, justificam a importância de pesquisas com foco no avanço da tecnologia agropecuária devido seu potencial de aumento da produtividade. Para garantir que a produção de alimentos continue em crescente otimização, faz-se necessário a inovação e o aprimoramento das técnicas de manejo dos animais e do pasto. A pesquisa em nutrição de ruminantes estuda a relação da alimentação com o desempenho de produção. O paradigma do cenário da pecuária é o conhecimento da interação do ruminante com as pastagens, porém isto só é possível caso se possua a tecnologia necessária, principalmente o monitoramento nutricional. Com fim de atingir tal objetivo, tem-se consolidado a prática de pecuária de precisão, a qual constitui-se da atividade de monitoramento do pastejo para avaliação do comportamento ingestivo. O objetivo dessa prática é padronizar e otimizar a produção dos produtos, melhor aproveitando o ambiente do pasto, melhorando o bem-estar animal e reduzindo riscos ambientais (TULLO et al., 2019).

Os métodos de avaliação quantitativa da ingestão existentes são diversificados na literatura, e cada um deles possui suas características próprias, complexidade, vantagens e desvantagens. Os métodos diretos (manuais) são geralmente laboriosos, invasivos ou impraticáveis em larga escala. Para compensar essa limitação, métodos eletrônicos tem sido desenvolvidos com o uso de sensores de pressão, de extensão, acústicos, ópticos e biomédicos (BÜCHEL; SUNDRUM, 2014; ANDRIAMANDROSO et al., 2016; CAMPOS

et al., 2016a). É nesse sentido que se torna interessante a procura por um método de monitoramento que não seja danoso ao animal e ao mesmo tempo possa realizar a amostragem e processamento de informação de maneira automática.

A análise de sinais sEMG possui como objetivo obter sinais provenientes da despolarização nervosa e muscular. Os sinais são medidos por meio de eletrodos de contato, geralmente eletrodos de prata/cloreto de prata (Ag/AgCl), posicionados sobre o músculo em estudo (HERMENS et al., 2000). A análise consiste em observar as características do sinal como amplitude, espectro de frequência, quantidade de potenciais, variabilidade da forma dos potenciais de ação e correlações entre esses atributos (STASHUK, 2001). A sEMG pode ser utilizada para avaliar a atividade dos músculos de mastigação, aplicando os eletrodos na região mandibular do animal, avaliando a amplitude dos sinais, o espectro de frequência entre outros atributos (KEMSLEY et al., 2002; WILLIAMS et al., 2007). Esse método apresenta vantagem em relação aos outros citados por não ser invasivo e pode indicar diretamente a habilidade de mastigação (FUEKI et al., 2008), detectar automaticamente a ingestão de alimentos em humanos (SAZONOV; FONTANA, 2012) e reconhecer padrões ingestivos em ruminantes (CAMPOS et al., 2018).

O desafio consiste em transformar o sinal bruto de sEMG em informação útil e de dimensão reduzida para investigação de padrões de alimentação e ruminação. Uma das limitações consiste na dificuldade em escolher a forma correta de reduzir esses sinais para o classificador. Uma das tendências em processamento de sinais biomédicos é o uso de representações esparsas (KRISHNAN; ATHAVALE, 2018; HAZARIKA et al., 2019), a qual consiste em técnicas usada para codificar e reconstruir sinais e que também tem sido usadas para finalidade de classificação. Portanto, a hipótese é que a utilização de técnicas de representações esparsas possam servir tanto para extrair características úteis para classificação quanto para compactar o sinal com pouca perda de informação.

O monitoramento automático do comportamento ingestivo de animais de fazendo é quase sempre feito por meio de sensores como acelerômetros tri-axiais, giroscópios e microfones acoplados em brincos, colares e buçais (ANDRIAMANDROSO A. L. H.; LEBEAU., 2016). As Unidades de Medida Inercial (IMU) são os sensores mais encontrados na literatura nos últimos anos para essa aplicação (FOGARTY et al., 2018; GONZÁLEZ et al., 2018) e são usados para identificar atividades de pastejo e ruminação (SMITH; GREENWOOD, 2017; GUO et al., 2018; MANSBRIDGE et al., 2018; TAMURA et al., 2019). Apesar de sua elevada taxa de precisão (acima de 90%), os dados inerciais obtidos por esses sensores são processados pelo janelamento de longas

épocas, e dessa forma, não atingem a precisão de uma mastigação individual. Essa técnica é puramente baseada na diferença de padrões dinâmicos da cabeça do animal. Assim, esse tipo de sensor não tem o potencial de acessar informações como o tipo de alimento sendo ingerido. Um tipo de sensor que possui essa capacidade é baseado em sensores de deformação baseado em redes de Bragg em fibra óptica, porém o método é invasivo (PEGORINI et al., 2015b).

O movimento mastigatório durante a ruminação e ingestão possuem diferentes aspectos fisiológicos, como a duração do ciclo e o fator de trabalho aplicado. A ingestão é iniciada por um bocado com rápida produção de força para processar o alimento, por outro lado a mastigação do *bolus* ruminal já pré-cominuído requer menor produção de força porém com movimentos mais longos. Essas atividades demandam diferentes níveis de força, duração do carregamento e deslocamento vertical e mediolateral da mandíbula (WILLIAMS et al., 2011). Dessa forma, a resposta eletromiográfica dos músculos mastigatórios devem conter a informação necessária para distinguir esses dois eventos ingestivos. Por essa razão, as medidas de sEMG do músculo masseter tem sido usadas em animais de fazenda para contar movimentos mastigatórios (BÜCHEL; SUNDRUM, 2014), identificar períodos de ingestão (RUS et al., 2013; CAMPOS et al., 2016a), classificar tipos de pasto sendo ingeridos (CAMPOS et al., 2018) e estimar o consumo de fibras (CAMPOS et al., 2019b). A classificação de padrões eletromiográficos, em geral, segue uma estrutura semelhante: extração de características, redução de dimensionalidade e classificação (CHOWDHURY et al., 2013). Os métodos estado-da-arte para classificação de EMG são baseados na busca por conjuntos de características que levam a melhores taxas de acerto e robustez (KHUSHABA et al., 2016; PHINYOMARK et al., 2018). Uma possível desvantagem desses métodos tradicionais se refere à estabilidade da performance à combinação de características e método de classificação. Não se pode garantir que um método que se demonstrou ótimo para determinada aplicação será também ótimo se houverem desvios no sinal, como por exemplo, se o nível de ruído for outro, se houverem mudança na posição do eletrodo, etc. Ademais, tem sido apontado que uma desvantagem da extração de características é que informações úteis podem ser descartadas (DING et al., 2018). Para mitigar esse problema, abordagens de aprendizado profundo (*Deep Learning*), como Redes Neurais Convolucionais (CNN), que operam como uma rede com características ocultas (classificação *end-to-end*), tem sido propostas (DING et al., 2018; HU et al., 2018). Contudo, as CNN demandam grandes bases de dados ou conjuntos de treinamentos típicos para evitar problemas de sobreajuste (Ahmadvand et al., 2016).

A representação esparsa de sinais usando um dicionário treinado tem sido usado para comprimir sinais de EMG por meio de codificação esparsa (BALOUCHESTANI; KRISHNAN, 2015). O dicionário é uma coleção de protótipos de sinais (também chamados de átomos), organizados em uma matriz, os quais são treinados para melhor representar os dados quando combinados linearmente. O método tem uma definição de representação esparsa pois a função objetivo é encontrar um vetor de mistura tão esparsa quanto possível e com menor erro de reconstrução. Essa família de técnicas tem sido apontada como uma tendência no processamento de sinais biomédicos (KRISHNAN; ATHAVALE, 2018).

Os métodos de Reconhecimento de Padrões Baseados em Representações Esparsas (SRC) e aprendizado de dicionário emergiram como uma alternativa aos métodos convencionais de extração de característica e aprendizado profundo. Esses métodos tem recebido atenção na classificação de padrões em imagens devido sua robustez e recentemente foram, pela primeira vez, utilizados na classificação de sinais miográficos (YOO et al., 2019). As abordagens de reconhecimento de padrões baseados em representações esparsas são significativamente menos sensíveis aos desvios de sinais (Betthauser et al., 2018) e superam métodos tradicionais quando o ruído aumenta (GENG et al., 2018). Ainda, a performance na classificação de sinais miográficos baseados em aprendizado de dicionário notável quando o número de canais é reduzido (YOO et al., 2019). Isso posto, essa família de técnicas tem o potencial de classificar sinais eletromiográficos (oriundos de um único canal) de eventos ingestivos com a precisão de uma única mastigação, os quais apresentam inúmeros desvios durante as atividades de mastigação.

## 1.2 OBJETIVOS

### 1.2.1 OBJETIVO GERAL

Identificar e classificar padrões ingestivos de animais ruminantes a partir da eletromiografia de superfície do músculo masseter utilizando técnicas de aprendizado de dicionário.

### 1.2.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos desse trabalho são:

1. Definir uma metodologia para identificação automática de movimentos mastigatórios no sinal eletromiográfico do músculo masseter em bovinos.
2. Avaliar e classificar sinais eletromiográficos utilizando metodologias sugeridas na literatura utilizando duas técnicas de segmentação de sinais.
3. Avaliar e classificar sinais eletromiográficos utilizando classificadores baseados em representações esparsas e aprendizado de dicionário.
4. Avaliar a robustez do método com relação a inserção de ruídos.

### 1.3 ESTRUTURA DO TRABALHO

O trabalho iniciar-se-á por uma revisão de literatura dos métodos eletrônicos usados para investigação do comportamento ingestivo em ruminantes (Capítulo 2), onde serão abordados: chave de contato; métodos extensiométricos e barométricos; métodos acústicos; redes de Bragg em fibra óptica; e métodos eletromiográficos. Também será percorrido os trabalhos realizado pelo autor até o momento que sucederam na presente pesquisa. Em seguida, é feita uma fundamentação teórica dos temas nevrálgicos para o entendimento da pesquisa (Capítulo 3). Serão abordados os princípios e a notação dos sinais de EMG, a formalização matemática das técnicas de codificação esparsa e aprendizado de dicionário. A metodologia empregada no trabalho (Capítulo 4) abrangerá o protocolo experimental para coleta de dados em animais, o *hardware* utilizado para medir os sinais, o pré-processamento dos sinais, o procedimento escolhido para segmentação do sinal, os métodos selecionados da literatura para extração de características e o processamento de sinais por meio da técnica proposta. Os resultados de segmentação e classificação dos sinais são descritos no capítulo de resultados (Capítulo 5), e por fim, a conclusão fará uma síntese com as principais contribuições e propostas para trabalhos futuros (Capítulo 6).



## 2 REVISÃO DE LITERATURA

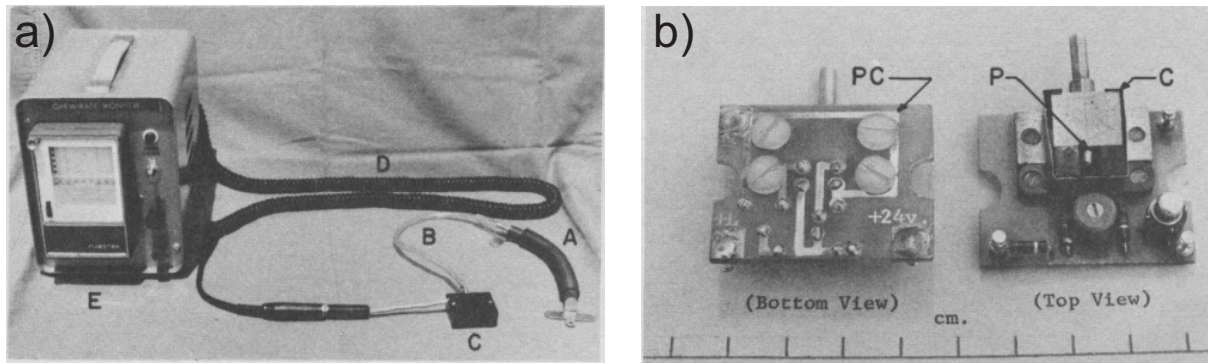
Equipamentos para monitoramento do comportamento ingestivo de ruminantes são citados desde a década de 70. Os primeiros sistemas envolviam chaves de contato e tubos de borracha preenchidos por ar ou material condutivo montados no cabresto. Quando o animal movimentava a mandíbula estes sensores geravam sinais que eram gravados em fitas. Com o avanço da eletrônica e a modernização dos dispositivos de gravação passaram a ser usados extensômetros, microfones e acelerômetros. Nos últimos anos, fibras ópticas e eletromiografia também foram aplicados para essa finalidade. Estas técnicas têm assumido linhas paralelas de pesquisa na literatura e disputam espaço entre si na comunidade científica.

### 2.1 CHAVES DE CONTATO

Um dispositivo eletrônico simples para a contagem de mastigações foi concebido por Law e Sudweeks (1975), conforme apresentado na Figura 2. O sistema completo mostrado na Figura 2a constitui-se de um tubo de borracha, o qual fica atado à mandíbula do animal, e é conectado a um pequeno sistema eletrônico acionado por uma chave do tipo cilindro-pistão por meio de um tubo. Ao movimentar a mandíbula na atividade de mastigação, o tubo sofre variações de volume que refletem em deslocamento do pistão. Um circuito eletrônico transforma os movimentos mecânicos em pulsos elétricos, que são conduzidos por meio de um cabo a um pneumógrafo com a função de registrar os movimentos mastigatórios. O circuito e a chave são mostrados em detalhes na Figura 2b. Neste circuito um acoplador óptico é montado junto a uma chave mecânica em uma placa de circuito impresso, de modo que a movimentação do pistão interrompe o acoplamento entre emissor e receptor de luminosidade, gerando pulsos.

Um sistema com funcionamento semelhante foi proposto por Luginbuhl et al. (1987), baseado na contagem de pulsos gerados por dois contatos metálicos. Um dos contatos está preso à um tubo de borracha, que é conectado à parte inferior da boca do

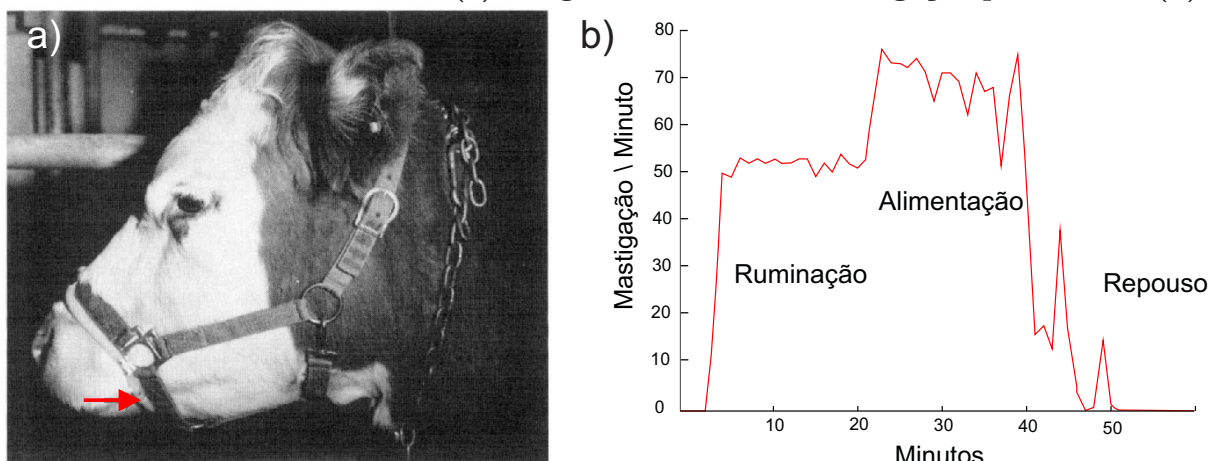
**Figura 2: Transdutor opto-eleto-mecânico de movimentos mastigatórios. Sistema de medição e registro (a) e detalhe do pulsador eletromecânico (b).**



Fonte: Law e Sudweeks (1975)

animal. Na lateral é posicionado outro contato metálico, de forma que o movimento de mastigação produz tensão na borracha, fazendo com que os contatos da parte inferior e lateral se encostem ou se afastem. Os pulsos gerados são condicionados por um circuito eletrônico e registrados por um computador. O tubo com contatos está mostrado na Figura 3a. Analisando a quantidade de mastigações (pulsos) no período de 1 minuto é possível obter uma curva de frequência de mastigação em função do tempo, como mostrado na Figura 3b. A frequência de mastigação é suficiente para identificar os períodos de ruminação, alimentação e repouso.

**Figura 3: Transdutor eletro-mecânico de movimentos mastigatórios. Tubo com contatos montado em cabresto (a) e registro da taxa de mastigação por minuto (b).**



Fonte: Adaptado de Law e Sudweeks (1975)

## 2.2 MÉTODOS EXTENSIOMÉTRICOS E BAROMÉTRICOS

Um estudo preciso do comportamento ingestivo dos animais ruminantes requer o emprego de técnicas de gravação eletrônica dos dados ou aproximações por análise visual. Em seu trabalho, Penning (1983) desenvolveu um método pioneiro de registro de movimentos mastigatórios utilizando sensores de deformação constituídos por tubos de borracha preenchidos por grafite granulado. Esse dispositivo requeria o uso de fitas cassete e, com o tempo, se tornou obsoleto devido ao desgaste mecânico do sistema de gravação. Observado isso, o sistema foi melhorado por Matsui e Okubo (1991), que utilizaram a gravação digital, permitindo o pós-processamento de maneira a obter os tempos de mastigação, ruminação e número de mastigações, apesar de não discriminar os movimentos de apreensão e mastigação. Uma variação desse sistema foi proposto por Rook et al. (1994), fazendo o uso de um gnatômetro, dispositivo intra-oral de registro da mordida, porém ainda fazia uso de fitas para gravação do sinal.

O método de Penning (1983) foi validado e testado por Matsui (1994) que constatou ser o melhor concebido até a época. As limitações foram corrigidas por Rutter et al. (1997) e o novo sistema denominado IGER<sup>1</sup> *Behavior Recorder* foi criado e refinado pela empresa *Ultra Sound Advice Ltd.*, todavia sua produção foi descontinuada (ULTRA SOUND ADVICE, 2014).

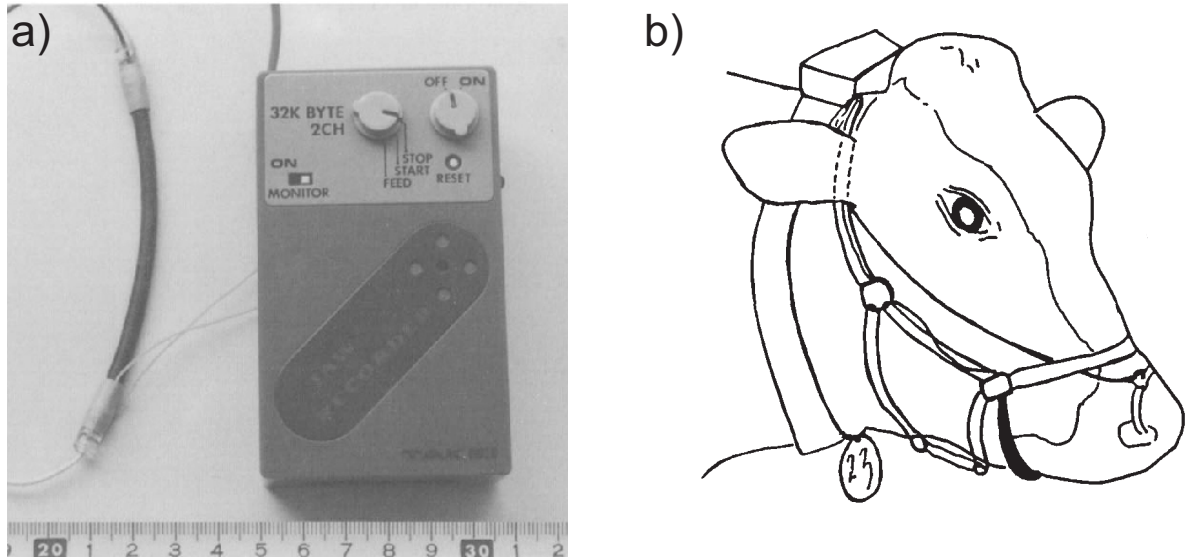
Esse método passou por diversos aprimoramentos, como o trabalho de Kononoff et al. (2002) ilustrado na Figura 4a. O método utiliza um sensor de deformação baseado em um tubo preenchido com grafite granulado fixado na parte inferior da mandíbula do animal de maneira que a resistência elétrica do sensor varia com os movimentos mastigatórios. Os sinais são gravados por um sistema de registro eletrônico. A montagem do sistema no animal é representada pela Figura 4b, onde a posição do sensor preso por meio de cabresto reflete os movimentos mandibulares que são transformados em sinais que são gravados em um sistema eletrônico fixado na parte anterior da cabeça do animal.

Quando os sistemas de gravação analógica foram substituídos pelos de gravação digital, o método se consolidou e foi utilizado em diversos trabalhos (RUTTER et al., 1997). Posteriormente, o processamento dos dados foi aprimorado por seus autores, incluindo um programa computacional de identificação automática nomeado *Graze* (RUTTER, 2000). Os avanços realizados levaram a uma precisão de 98,7% na contagem de movimentos mastigatórios (UNGAR; RUTTER, 2006), o que fez com que

---

<sup>1</sup>*Institute of Grassland and Environmental Research* (Instituto de Pastagem e Pesquisa Ambiental).

**Figura 4: Sensor de deformação utilizando tubo preenchido com grânulos de carbono. Sensor a esquerda e sistema DAQ a direita (a) e sistema completo no animal (b).**



**Fonte: Adaptado de Kononoff et al. (2002), Matsui (1994)**


pesquisas posteriores utilizassem essa técnica (BREMM et al., 2012; AMARAL et al., 2013).

Outro sistema de registro de extensão mandibular desenvolvido na década de 1980 (BEAUCHEMIN et al., 1989) contava com um sistema sem tubos, conforme mostrado na Figura 5. Na Figura 5a é apresentada a composição do sensor, formado por um extensômetro ou *strain gauge* montado sobre uma mola plana de aço fixada entre dois tapetes de borracha recobertos por tecido elástico e preso por rebites. Na Figura 5b é ilustrada a montagem do sistema na cabeça do animal, onde o sensor posicionado na parte inferior na mandíbula transforma a deformação da borracha em sinais elétricos. A fixação do sensor é realizada através de cabresto e os sinais são transmitidos por cabo flexível.

Uma outra linha de pesquisa na época propôs posicionar balões de borracha ou silicone preenchidos por ar debaixo do cabresto dos animais, sendo posicionados na parte inferior da mandíbula (DESWYSEN; ELLIS, 1990; BOEVER et al., 1993). Ao passo que o animal ingere o alimento, cria-se uma diferença de pressão no aparato que é transformado em grandeza elétrica por meio de um sensor de pressão.

O método foi posteriormente modificado utilizando tubos preenchidos de óleo acoplados à sensores de pressão. Esse novo sistema foi validado para a função de

**Figura 5: Sensor de deformação utilizando extensômetro. Montagem do transdutor (a) e sistema completo no animal (b).**



**Fonte: Beauchemin et al. (1989)**


contagem de movimentos mastigatórios, apresentando elevado valor de correlação em relação à contagem visual (ZEHNER et al., 2017; ROMBACH et al., 2018), entretanto sua performance na estimação de consumo se mostrou abaixo dos demais métodos atuais (LEIBER et al., 2016). Mais recentemente, resultados preliminares indicam a possibilidade de identificar padrões a partir dos dados desse sensor, embora a precisão temporal seja de 1 minuto (BENAISSA et al., 2019).

### 2.3 MÉTODOS ACÚSTICOS

Apesar dos avanços realizados pelos métodos apresentados, o método acústico foi recomendado para contagem de movimentos mastigatórios devido a capacidade de distinguir movimentos de mastigação e de apreensão (NADIN et al., 2012). Nesse contexto, os métodos acústicos surgem com objetivo de registrar o comportamento ingestivo dos animais de maneira automática por meio da gravação de ruídos do pastejo. O método não é invasivo, envolve apenas a colocação de um microfone na cabeça do animal por meio de um cabresto (Figura 6), visando identificar a atividade de pastejo, ruminação entre outras atividades (TRINDADE, 2011).

Este método se desenvolveu a partir dos trabalhos de Laca et al. (1994) e Distel et al. (1995), em que se utilizava gravação de áudio e vídeo para auxiliar na investigação do

Figura 6: Sistema de aquisição de sinais bioacústicos. Microfone lateral (a) e microfone na parte anterior da cabeça do animal (b).



Fonte: Adaptado de Clapham et al. (2011), Trindade (2011)

comportamento ingestivo. Nesses trabalhos, a análise de dados não era automatizada, sendo ela feita por um observador. A gravação do som, além de não interferir no comportamento do animal em pastejo, possui a vantagem de conter informações que vão além dos tempos de atividades de pastejo, como a distinção entre movimentos de mastigação, apreensão e movimentos compostos (mastigação-apreensão<sup>2</sup>) (MILONE et al., 2012) e estimativa de Consumo de Matéria Seca (CMS) (GALLI et al., 2006). Essas variáveis são úteis para quantificar os parâmetros de consumo de forragem e podem servir para estudo da distribuição espacial e temporal do consumo (LACA; WALLISDEVRIES, 2000). O método pode ser usado com objetivo de avaliar as taxas de bocados e mastigação, somando mais informações para a previsão de ingestão, embora ainda não exista uma técnica de previsão automática de consumo diário e reconhecimento das forragens (GALLI et al., 2011).

O sistema desenvolvido por Clapham et al. (2011) é representado na Figura 6a. O microfone é colocado na lateral do cabresto próximo à boca do animal e o DAQ é preso no topo. Algumas limitações são citadas pelo autor como objetivos para o próximo sistema a ser desenvolvido: estimação de consumo diário e gravação de longos períodos de pasto, restrito pela memória de armazenamento dos dados. As desvantagens do método compreendem a necessidade de calibração do circuito para cada animal e os ruídos acústicos, que podem ser de natureza externa, como o barulho do vento, e provindos da mastigação de outro animal, que podem gerar falsa classificação.

<sup>2</sup>É citado na literatura como *chews* (mastigação), *bites* (bocado) e *chew-bites* (movimentos mistos ou compostos), *ipsis litteris* (MILONE et al., 2012).

Uma topologia alternativa foi utilizada por Trindade (2011), cujo arranjo é mostrado na Figura 6b. Neste trabalho, todo o sistema foi fixado no topo da cabeça do animal, ou seja, um microfone de lapela fixado da parte anterior da cabeça do animal e o dispositivo de Aquisição de Dados (DAQ) no topo (parte posterior da cabeça). As duas topologias possuem peculiaridades, uma vez que o sinal terá mais qualidade ao posicionar o microfone mais próximo da boca, no entanto terá menor relação de ruído de origem eletromagnética posicionando o microfone mais próximo do dispositivo DAQ (NATIONAL INSTRUMENTS, 2014).

Apesar da topologia utilizada por Trindade (2011) ser rotulada como automática, a diferenciação dos alimentos e dos bocados era feita, a princípio, por um observador que fazia a identificação por inspeção visual dos sinais, como em Laca et al. (1994). Os trabalhos de Milone et al. (2009) e Milone et al. (2012) apresentam métodos computacionais de identificação baseados em um modelo oculto de Markov. O *software Hi-Tag* utilizados por Schirmann et al. (2009) fornece informações como tempos de ruminção, intervalos entre a regurgitação do *bolus* e taxa de mastigação, porém a maneira como o programa processa os dados brutos não é totalmente transparente.

## 2.4 MÉTODOS ACELEROMÉTRICOS

O uso de sensores de aceleração tri-axiais (acelerômetros) com finalidade de estimar o tempo de pastejo foi primeiro descrito por Scheibe et al. (1998) em um sistema chamado *Ethosys GmbH*. Apresentado como uma inovação no estudo do comportamento ingestivo, o sistema se propunha a investigar qualquer comportamento que pudesse ser representado por leituras de aceleração. O aparato foi utilizado posteriormente em trabalhos que investigavam a preferência animal por determinadas alturas de pasto (GINANE et al., 2003).

Outro sistema utilizando o mesmo sensor foi investigado por Oudshoorn et al. (2013). O sensor foi fixado no pescoço de vacas, e a aceleração da cabeça do animal no momento do arranquio<sup>3</sup> foi utilizada como parâmetro. Outro sensor é acoplado nas pernas do animal com objetivo de avaliar o tempo de repouso, usando como gatilho o momento em que o animal deita. O método se mostrou eficaz em estimar tempo de alimentação comparado com o método visual (74% dos movimentos registrados pelo sensor foram observados). Entretanto, o método não foi capaz de diferenciar pastejo dos movimentos de procura por pasto.

---

<sup>3</sup>Arranquio: ato ou efeito de ceifar uma planta (ORMOND, 2006).

Um sistema análogo, chamado *Lifecorder Plus*, foi apresentado por Delagarde e Lamberton (2015), mostrando uma precisão de 95% na estimativa de tempo de pastejo. Segundo os autores, a limitação do método é a necessidade do conhecimento da altura do pasto para atingir essa precisão.

O método acelerométrico tem sido o método mais utilizado recentemente na literatura para o monitoramento do comportamento ingestivo animal. Especificamente, tem-se explorado a possibilidade de diferenciar padrões de ingestão e ruminação (GIOVANETTI et al., 2017; BARWICK et al., 2018; TAMURA et al., 2019) a partir da extração de características de segmentos do sinal de aceleração. Apesar desses trabalhos atingirem precisões acima de 90%, as épocas de processamento (dimensão das janelas), não atingem a precisão temporal de um bocado ou movimento mastigatório. Além disso, como os padrões estão associados aos movimentos da cabeça do animal durante cada atividade, esse tipo de sistema apresenta sensibilidade ao ambiente, como por exemplo, a altura de pasto. Ainda, visto que esse tipo de sensor detecta apenas características dinâmicas do animal, e não fisiológicas, não é possível acessar informações sobre o processo do ciclo mastigatório ou sobre o alimento sendo ingerido.


## 2.5 REDES DE BRAGG EM FIBRA ÓPTICA

De maneira análoga ao método do sensor de deformação, Wosniak et al. (2012) propuseram o emprego de sensores do tipo redes de Bragg para avaliação da mastigação. Redes de Bragg em fibra óptica (FBG) são padrões periódicos birrefringentes, foto-induzidos, impressos por luz Ultravioleta (UV) polarizada, ao longo de uma fibra óptica (HILL; MELTZ, 1997). O comprimento da onda eletromagnética na fibra varia com tensão mecânica aplicada na mastigação, o qual é transduzido de sinal óptico para sinal elétrico por um interrogador óptico. O biossensor foi aplicado *in vivo* em um bovino por Pegorini (2015). O método constitui-se em implantar cirurgicamente uma malha metálica de titânio na mandíbula do animal, operando como transdutor, e em seguida fixar o sensor no centro da malha com cola de cianoacrilato. A fibra é inserida em um tubo de silicone biocompatível por meio de fita microporosa para o exterior do animal. A montagem do sensor pode ser observada na Figura 7a. O esquema de aquisição de sinais, ilustrado na Figura 7b, é realizado pela fibra, a qual estabelece a comunicação com um interrogador óptico que envia os dados para um computador.

Foram ofertados ao animal alimentos com diferentes texturas, de maneira que as classes foram: repouso, ruminação, azevém, feno de Tifton e alimento concentrado. Os



**Figura 7: Sistema de aquisição de dados e posicionamento do biossensor baseado em redes de Bragg em fibra óptica. Montagem do sensor (a) e instrumentação e aquisição de sinais (b).**




**Fonte: Adaptado de Karam et al. (2015)**

dados foram amostrados pelo interrogador óptico com uma taxa de amostragem de 1 kHz e segmentados a cada 1000 ms. Foram utilizados como vetor de atributos os 1000 pontos relativos a 1 segundo de atividade mastigatória e 16 componentes de frequência obtidos pela Transformada de Fourier (PEGORINI et al., 2015b, 2015c). Utilizando redes neurais artificiais atingiu-se 93,3% de exatidão (PEGORINI et al., 2015b) e utilizando árvores de decisão, 94% de exatidão (PEGORINI et al., 2015a). Apesar da elevada taxa de acertos, por utilizar um interrogador óptico, o sistema ainda não é miniaturizável, além de ser um método invasivo.

## 2.6 MÉTODOS ELETROMIOGRÁFICOS

Com a finalidade de estimar os tempos de ruminção de vacas leiteiras, pesquisadores alemães fizeram uso da técnica de eletromiografia (BÜCHEL; SUNDRUM, 2014). O sistema concebido, mostrado na Figura 8, é formado por eletrodos metálicos (Figura 8b), um módulo contendo acelerômetro e um registrador de dados (Figura 8a), e um *software* de avaliação. Através de eletrodos posicionados na pele do animal sobre o músculo *masseter*, os sinais de sEMG são adquiridos e transmitidos via radiofrequência para uma base receptora (Figura 8c), a qual fica conectada a um computador. Os dados pós-processados indicam os períodos de atividade ingestiva e repouso. O trabalho publicado não apresenta informações aprofundadas sobre o sistema utilizado.

**Figura 8:** Instrumento de medição Myo-Sensor MS15 desenvolvido pela empresa Bitsz Engineering. Um módulo (a) faz aquisição de sEMG por eletrodos metálicos secos (b) conectados por meio de cabo. O módulo transmite os dados via radiofrequência para uma base receptora (c).



**Fonte:** Adaptado de Bitsz Engineering (2014)

O sistema, chamado na literatura de *DairyCheck*, foi desenvolvido pela empresa *Bitsz Engineering GmbH*, publicado com o nome comercial *Myo-Sensor MS15*. O sistema possui sensores de atividade muscular (eletromiografia), temperatura ambiente, temperatura da pele animal e acelerômetro triaxial. Os dados são enviados a uma base via radiofrequência com uma frequência de transmissão de 2,4 GHz com um alcance de até 100 metros. A taxa de amostragem é de 10 Hz (BITSZ ENGINEERING, 2014).

Este novo dispositivo possui uma proposta limitada, pois não realiza análises mais complexas, como a classificação de alimento ingerido e estimativas de consumo. Isso se deve à taxa de amostragem do sistema de 0,01 ksp/s (10 amostras por segundo), a qual não atende aos requisitos para aquisição de sinais eletromiográficos recomendados pela literatura (MAMBRITO; LUCA, 1984; LUCA, 1997; STASHUK, 2001). Ademais, os dados são analisados visualmente para determinação dos tempos de ruminação e alimentação.

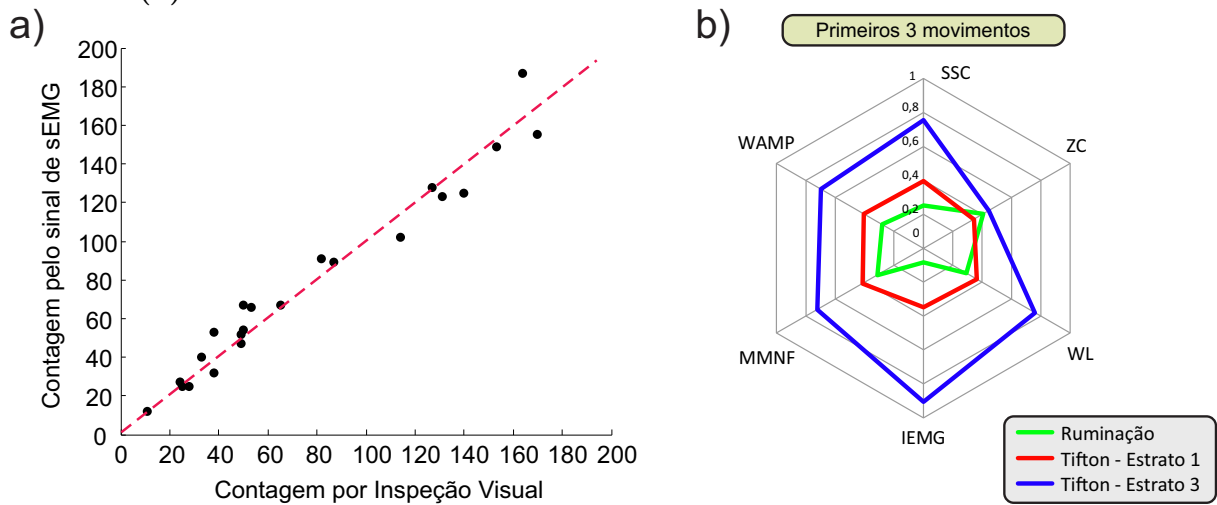
## 2.7 TRABALHOS ANTECESSORES

O presente trabalho se situa no contexto de um projeto que se iniciou em 2014, quando diversos métodos para avaliação do comportamento ingestivo animal estavam surgindo. Nesse período, os métodos eletromiográficos ainda não tinham aparecido na literatura, e pareciam ser uma solução alternativa viável para o problema. Enquanto as ideias iniciais estavam sendo testadas, Büchel e Sundrum (2014) publicou o artigo que seria a primeira ocorrência do método na literatura. Embora tenha sido o primeiro, corroborando com a ideia proposta, o método ainda parecia não aproveitar o potencial da

técnica.

Durante os anos de 2015 e 2016, dados de EMG foram coletados do músculo masseter de caprinos por um módulo de aquisição de biopotenciais em diversos experimentos pilotos em uma cooperação entre a Universidade Tecnológica Federal do Paraná (UTFPR) e o Instituto Agrônomo do Paraná (IAPAR). Em 2016 foram publicados os primeiros avanços do trabalho. Em um teste onde se ofertavam ramos em quantidades conhecidas de pasto pode-se verificar que utilizando uma técnica de segmentação de sinal EMG era possível contar com precisão o número de movimentos mastigatórios como mostra a Figura 9a (CAMPOS et al., 2016b). Ainda, verificou-se por uma coleta feita com leivas que atributos do sinal de EMG se modificava em diferentes alturas de pasto e durante a ruminação, principalmente durante os primeiros movimentos mastigatórios como exibido no diagrama em radar da Figura 9b (CAMPOS et al., 2016a).

**Figura 9: Resultados obtidos dos primeiros experimento de investigação do comportamento ingestivo em ruminantes a partir de EMG: contagem automática de movimentos mastigatórios (a) e análise de características do sinal em diferentes cenários (b).**



Fonte: Campos et al. (2016b) e Campos et al. (2016a)

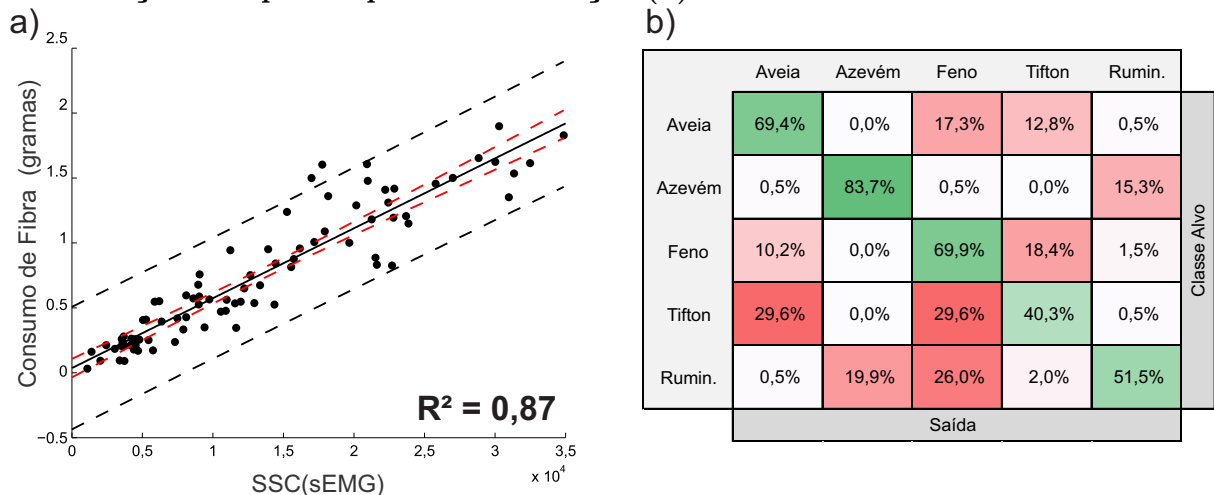
A partir de 2016 outros membros compuseram o grupo, auxiliando no desenvolvimento de um hardware específico<sup>4</sup> (GOMES et al., 2017) para as coletas, no estudo de eletrodos alternativos (MOSER et al., 2017) e na investigação do uso dos dados de EMG para estimar consumo de curto-prazo (BAIOCO et al., 2017). Posteriormente, após apuração dos dados de caprinos consumindo quantidades conhecidas de diferentes pastos, foi possível determinar um modelo de estimação de consumo de curto prazo

<sup>4</sup>Patente pendente.

utilizando dados de eletromiografia como preditores<sup>5</sup>. O estudo mostrou que cada pasto apresentava uma curva própria do consumo de matéria seca em função de um atributo de EMG com alto grau de correlação, chegando a um  $R^2$  de 0,90 para Tifton-68. Não obstante, ao converter os dados da massa de matéria seca para a massa relativo ao conteúdo de fibras, notou-se que todas as curvas se aproximavam independentemente do tipo de pasto, resultando em um modelo único de consumo de fibras em função de EMG, exibido na Figura 10a, com  $R^2$  de 0,87 (CAMPOS et al., 2019b).

Mais recentemente avaliou-se que os sinais de EMG continham a informação necessária para identificar padrões sobre o alimento sendo ingerido por meio de técnicas de aprendizado de máquina<sup>6</sup>. Foram avaliados 4 tipos de alimento (feno, Tifton, aveia e azevém) e ruminação, onde se observou uma precisão global de 63% e chegando ao máximo de 84% no reconhecimento de pasto de azevém (CAMPOS et al., 2018). A matriz de confusão dos resultados de classificação é mostrada na Figura 10b. Esse resultado trouxe a tona a necessidade de buscar-se por técnicas mais apuradas de classificação. Mais tarde, por meio de coletas em bovinos, confirmou-se que os pontos fulcrais eram a metodologia de segmentação de dados e a escolha correta do classificador e das características do sinal de EMG (CAMPOS et al., 2019a).

**Figura 10: Resultados mais recentes da investigação do comportamento ingestivo em ruminantes a partir de EMG: estimativa de consumo de curto-prazo (a) e classificação de tipos de pasto e ruminação (b).**



Fonte: Campos et al. (2019a) e Campos et al. (2018)

Após os esforços realizados na busca de um método capaz de classificar e

<sup>5</sup>Trabalho publicado no periódico Biosystem Engineering (Elsevier) em Julho de 2019.

<sup>6</sup>Trabalho publicado no periódico Computers and Electronics in Agriculture (Elsevier) em Outubro de 2018.

quantificar padrões ingestivos de ruminantes, pode-se identificar algumas limitações nos trabalhos realizados. Primeiro, a susceptibilidade dos dados de eletromiografia à fatores externos como ruídos, posicionamento de eletrodos e condições ambientais, impossibilitam uma escolha invariável de técnicas de extração de características. Segundo, as técnicas de segmentação e classificação de eventos ingestivos devem ser apuradas. Por final, o conjunto de técnicas propostas ainda não possibilita implementação em tempo-real, principalmente pelo custo de segmentação e da complexidade das características extraídas.

## 2.8 CONSIDERAÇÕES

Diversas técnicas baseadas em diferentes sensores com inúmeras técnicas de processamento tem sido propostas ao longo dos últimos anos com a finalidade de classificar, quantificar e modelar o comportamento ingestivo em animais ruminantes. Após acompanhar e estudar as técnicas presentes na literatura e ao mesmo tempo explorar um método baseado em eletromiografia, pode-se identificar suas limitações, desvantagem e vantagens. A partir disso, tem-se buscado continuamente soluções para os problemas mais prementes. Nesta circunstância, os avanços feitos neste trabalho são os resultados não publicados, conseguintes da pesquisa feita pelo autor ao longo dos últimos anos.

### 3 FUNDAMENTAÇÃO TEÓRICA

Um dos desafios do processamento de biosinais é investigar e determinar qual a quantidade de informação útil e como acessá-las. O objetivo é transformar dados brutos, os quais possuem alta dimensionalidade e nem sempre podem ser usadas diretamente em classificadores. A sEMG é um sinal que necessita essa transformação por ser constituído de uma mistura de diversos sinais oriundos de grupos musculares. Na literatura discutem-se quais características<sup>1</sup> do sinal de sEMG são mais adequadas para cada processo cinesiológico. Nessa busca exaustiva voltada para cada aplicação, muitas vezes chamada de *handcrafted features* (características feitas a mão), surgem métodos de extração sistemática, *e.g.*, a representação esparsa de sinais por meio de dicionários.

#### 3.1 ELETROMIOGRAFIA (EMG)

A medição de sinais eletromiográficos é feita por eletrodos internos ou de superfície. Quando o objetivo é analisar uma fibra específica, é recomendado o uso de eletrodos internos, como agulhas ou micropipetas (MERLETTI; PARKER, 2004). Se o músculo analisado está em movimento, o eletrodo de superfície é mais recomendado do que os internos. Entretanto, seu uso é restrito aos músculos superficiais grandes o suficiente para o posicionamento na pele (KAMEN; GABRIEL, 2010).

Os eletrodos de agulha são utilizados para diagnóstico e investigação de dores e distúrbios musculares como as miopatias, enquanto os de superfície indicam o esforço requerido para executar uma dada atividade (SELLA, 2007). Esses eletrodos também são utilizados para fazer o registro da atividade de músculos profundos, em que uma haste concêntrica é colocada na região específica da unidade motora que se deseja analisar (CLARK et al., 1992). O eletrodo de agulha é ideal para detectar potenciais em um volume de tecido limitado, entretanto, a agulha deve ser movida ou retirada e reinserida

---

<sup>1</sup>As características são transformações ou cálculos realizados no vetor ou na matriz de dados para obter um vetor ou matriz o mais reduzido possível que ainda preserve ou revele informações para interpretação ou modelagem de um determinado processo.

várias vezes em outros compartimentos para se obter uma atividade representativa a unidade muscular (DAUBE, 2002).

Devido sua característica não invasiva e de fácil manuseio, na maior parte dos casos de registro de sinais musculares os eletrodos de superfície são utilizados, apesar de possuírem desvantagem de apenas serem sensíveis aos músculos superficiais. Dentre os transdutores de biopotencial de superfície, os eletrodos autoadesivos de Ag/AgCl são os mais usados e recomendados. Além da rápida aplicação, os aspectos de higiene não são um problema por serem descartáveis (KONRAD, 2006). O eletrodo de superfície registra a atividade elétrica ao nível da pele das células excitáveis evocadas na região (DAUBE, 2002). Infelizmente, os potenciais de músculos não relacionados são somados no sinal de interesse, sendo chamados de *cross-talk*. Esse efeito é particularmente problemático quando se deseja analisar músculos menores em um arranjo muscular complexo (KAMEN; GABRIEL, 2010).

A musculatura esquelética é organizada em Unidades Motoras (MU), sendo que a menor unidade que pode ser ativada por esforço voluntário é formalmente definida como um alfa-motoneurônio (CRAM; CRISWELL, 2011). A MU é constituída de fibras, que podem fazer parte de uma ou mais unidades.

O elemento fundamental que constitui os sinais de EMG é o Potencial de Ação da Fibra Muscular (MFAP), derivado da propagação de um potencial de ação ao longo da membrana de uma única fibra. As características dependerão do diâmetro da fibra, da velocidade de condução e da posição relativa e configuração dos eletrodos. O potencial extracelular evocado por uma fibra ativa tem uma duração de 3 a 15 ms e amplitude de 20 a 2000  $\mu\text{V}$  medido ao nível da pele e a frequência dos pulsos varia de 6 a 30 descargas por segundo. A magnitude das componentes de alta frequência de um MFAP é inversamente proporcional à distância entre os eletrodos e a fibra, e diretamente proporcional à área do eletrodo (KAMEN; GABRIEL, 2010).

Normalmente, os potenciais registrados por eletrodos de superfície não podem ser identificados individualmente, visto que a medida é composta por uma soma dos MFAP em uma MU, sendo chamado de Potencial de Ação da Unidade Motora (MUAP). Denotando a forma de onda que propaga na  $i$ -ésima fibra como  $MFAP_i(t)$  e o potencial detectado quando a  $j$ -ésima unidade motora dispara como  $MUAP_j(t)$ , define-se (STASHUK, 2001):

$$MUAP_j(t) = \sum_{i=1}^{N_j} MFAP_i(t - \tau_i) s_i, \quad (12)$$

em que  $\tau_i$  expressa o *offset* temporal do  $MFAP_i(t)$ ,  $N_j$  o número de fibras na unidade motora e  $s_i$  uma variável que representa a ativação da junção neuromuscular da  $i$ -ésima fibra.

Para manter ou aumentar a força muscular a MU dispara um trem de pulsos e assim gera múltiplos MUAPs separados por intervalos. Essa sequência é chamada de Trem de MUAPs (MUAPT), e pode ser equacionado como (STASHUK, 2001):

$$MUAPT_j(t) = \sum_{k=1}^{M_j} MUAP_{jk}(t - \delta_{jk}), \quad (13)$$

em que  $MUAPT_j(t)$  é o trem de potenciais da  $j$ -ésima MU,  $MUAP_{jk}(t)$  é o MUAP gerado durante o  $k$ -ésimo disparo da  $j$ -ésima MU,  $M_j$  é o número de vezes que a  $j$ -ésima MU dispara e  $\delta_{jk}$  é o  $k$ -ésimo tempo de disparo da  $j$ -ésima MU. Devido a variações biológicas a forma de cada MUAP é única, porém deve-se observar um alargamento dos potenciais e aumento da frequência dos MUAPTs ao ocorrer uma elevação dos níveis de força (STASHUK, 2001).

O eletrodo de superfície mede a soma temporal e espacial das contribuições dos potenciais devido ao princípio da superposição. Logo, o sinal de EMG é a soma dos MUAPTs dos  $N_m$  MUs recrutadas somado a um ruído  $n(t)$  presente no sistema de instrumentação (STASHUK, 2001):

$$EMG(t) = \sum_{j=1}^{N_m} MUAPT_j(t) + n(t). \quad (14)$$

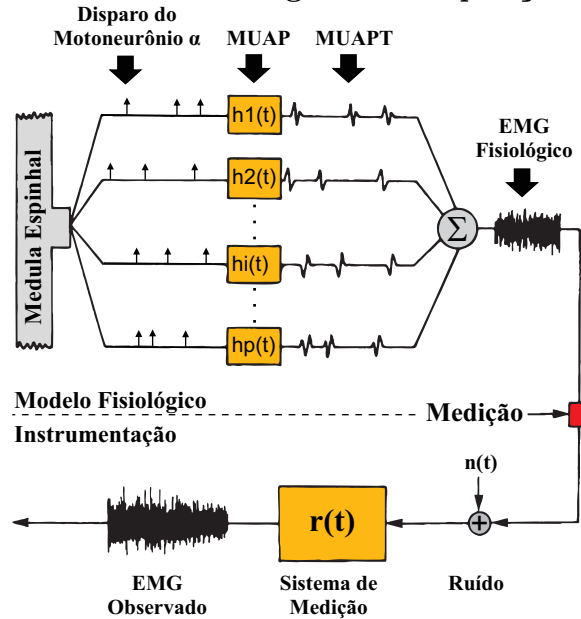
A Figura 11 mostra a composição do sinal de EMG. Os impulsos provenientes da medula espinhal são os disparos do motoneurônio. Os blocos representados por  $h_i$  são sistemas que representam o potencial de ação da fibra muscular. A soma dos trens de potenciais compõem o sinal de EMG. O sinal somado ao ruído presente na instrumentação é medido pelos eletrodos e equipamento de aquisição representado por  $r(t)$ . A saída do sistema é o sinal de EMG observado.

### 3.2 REPRESENTAÇÃO ESPARSA

A escolha das características dependem de uma análise voltada para a aplicação, e dessa a forma, encontrar a melhor combinação requer uma busca exaustiva. Para mitigar essa limitação utilizam-se métodos de extração sistemática (*non-handcrafted features*).



Figura 11: Modelo matemático e fisiológico da composição de um sinal de EMG.



Fonte: Adaptado de Stashuk (2001)

Um exemplo é o uso de dicionários, o qual se constitui por uma transformação linear capaz de codificar o sinal em um vetor esparso (componentes) e reconstruí-lo pela misturas dos componentes com essa matriz. Diversos dicionários são descritos na literatura, embora seja possível treiná-los a partir de um conjunto de dados a serem representados.

Modelagem esparsa é o conjunto de técnicas que visa representar sinais através de vetores cujos elementos são majoritariamente nulos. A Figura 12 exemplifica a reconstrução de um dado por meio de sua representação esparsa. Considerando um vetor  $\mathbf{y} \in R^n$ , um dicionário é uma matriz  $\mathbf{D} \in R^{n \times K}$  contendo protótipos de sinais em suas colunas (chamadas de átomos) a qual reconstrói  $\mathbf{y}$  ao ser multiplicada por um vetor esparso de componentes  $\mathbf{x} \in R^K$ . O produto  $\mathbf{D}\mathbf{x}$  faz com que cada elemento não nulo selecione determinadas colunas do dicionário, por exemplo, o  $j$ -ésimo elemento não nulo do vetor esparso produz uma contribuição  $\mathbf{d}_j x_j$  para o sinal, em que  $x_j$  é um escalar real e  $\mathbf{d}_j$  um vetor de protótipo (um átomo do dicionário). A soma dessas contribuições resultam em uma aproximação do sinal  $\mathbf{y}$ . Essa aproximação pode ser exata ( $\mathbf{y} = \mathbf{D}\mathbf{x}$ ) ou aproximada ( $\mathbf{y} \approx \mathbf{D}\mathbf{x}$ ).

Dicionários comumente usados são transformadas como a transformada de Fourier e as famílias de transformadas Wavelet. Conhecendo o dicionário adequado para representar o sinal é possível encontrar as componentes do vetor esparso que a representam por meio de uma codificação esparsa (ELAD, 2010). A base teórica da codificação esparsa

Figura 12: Representação esparsa de sinais.

$$\mathbf{y} = \mathbf{D} \mathbf{x}_j = \mathbf{d}_j x_j + \dots$$

Fonte: Autoria própria

é apresentada em detalhes no Apêndice A.

### 3.3 CLASSIFICAÇÃO BASEADA EM APRENDIZADO DE DICIONÁRIO

A principal ideia do aprendizado de dicionário é encontrar uma representação esparsa de um sinal ou imagem usando um dicionário de átomos<sup>2</sup>, construído a partir de um conjunto de treinamento pré-definido. Então, o objetivo, seja a reconstrução ou classificação, do sinal ou imagem, pode ser otimizado, visto que o dicionário é ajustado no domínio do problema (YANG et al., 2014). Em contraste com os métodos convencionais, pode-se imaginar que o dicionário está aprendendo de maneira supervisionada os elementos que compõe o sinal ao invés de extrair um conjunto de métricas que reduzem a dimensionalidade do sinal e tentam manter informações embutidas nele. Outra diferença é que o conceito de característica deve ser reinterpretado. Em técnicas de aprendizado de dicionário, uma instância é classificada a partir de uma medida de semelhança entre o sinal investigado e a representação pelos dicionários específicos. Nas técnicas convencionais, as características extraídas de modo não-supervisionadas projetam o sinal em um espaço multi-dimensional onde espera-se que exista um hiperplano que as dividem.

Existem diversas abordagens de aprendizado baseadas em dicionários. Os métodos de aprendizado de dicionário podem ser divididos em dicionários compartilhados, específicos à classe, comunalidade e particularidade<sup>3</sup>, auxiliar e de domínio

<sup>2</sup>Os átomos são os elementos, geralmente colunas, do dicionário (protótipos de sinais) os quais são linearmente combinados por um vetor esparsa para gerar uma reconstrução mais próxima possível dos dados de entrada.

<sup>3</sup>Tradução livre do termo *commonality and particularity*.

adaptativo (XU et al., 2017).

Um algoritmo de aprendizado de dicionário compartilhado é normalmente usado quando a ideia é extrair características comuns de todo o conjunto de dados, sem preservar atributos específicos de cada classe. Um dicionário específico à classe por outro lado, consegue manter os atributos principais de cada classe, i.e., apresenta decomposição esparsa discriminativa entre cada classe. O aprendizado de dicionário por comunalidade e particularidade preserva aspectos comuns e específicos das classes na base de dados, o que pode comprometer especificamente tarefas de classificação. Um algoritmo de dicionário auxiliar utiliza exemplos isolados (*outliers*) para representar possíveis variações das amostras em um conjunto de dados previamente conhecido. Por fim, o algoritmo de aprendizado de dicionário que aplica o conceito de domínio adaptativo é usado para tratar de casos onde os conjuntos de treinamento e teste possuem distribuições distintas.

Neste trabalho, foi escolhido um algoritmo de aprendizado de dicionário específico à classe chamado de modelo de Aprendizado de Dicionário por Discriminante de Fisher (FDDL, do inglês *Fisher Discrimination Dictionary Learning*) apresentado por Yang et al. (2014), devido sua habilidade de melhorar o desempenho de classificação, mantendo a esparsidade da representação dos sinais ou imagens de entrada (YANG et al., 2014; XU et al., 2017). Esse método tem sido o predecessor de outros algoritmos similares, que utilizam o mesmo conceito com restrições específicas (FENG et al., 2013; ZHENG; TAO, 2015; Vu et al., 2016; VU; MONGA, 2016).

O método FDDL aprende um dicionário individual para cada uma das  $M$  classes,  $\mathbf{D} = [\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_M]$ , onde  $\mathbf{D}_i$  é o sub-dicionário da classe  $i$ . Dado um conjunto de dados de treinamento  $\mathbf{A} = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_M]$ , a matriz de representação esparsa de  $\mathbf{A}$  sobre  $\mathbf{D}$  é denotada por  $\mathbf{X}$ . Isso significa que  $\mathbf{A}$  pode ser reconstruído por  $\mathbf{D}$  e  $\mathbf{X}$  a partir de  $\mathbf{A} \approx \mathbf{D}\mathbf{X}$ . Adicionalmente, é válido escrever  $\mathbf{X}$  como  $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M]$ , onde  $\mathbf{X}_i$  é a matriz de representação específica à classe do conjunto  $\mathbf{A}_i$  sobre o dicionário  $\mathbf{D}$ , ou seja,  $\mathbf{A}_i \approx \mathbf{D}\mathbf{X}_i$ . Além disso, é requisitado que  $\mathbf{D}$  tenha a capacidade de distinguir as classes dos dados em  $\mathbf{A}$ . Posto isso, o modelo FDDL pode ser definido por:

$$\begin{aligned} J(\mathbf{D}, \mathbf{X}) = \underset{\mathbf{D}, \mathbf{X}}{\operatorname{arg\,min}} \{ & r(\mathbf{A}, \mathbf{D}, \mathbf{X}) + \lambda_1 \|\mathbf{X}\|_1 + \lambda_2 f(\mathbf{X}) \}, \\ \text{s.t. } & \|\mathbf{d}_n\|_2 = 1, \forall n, \end{aligned} \tag{15}$$

onde  $r(\mathbf{A}, \mathbf{D}, \mathbf{X})$  é um termo de fidelidade de discriminação dos dados;  $\|\mathbf{X}\|_1$  é um termo

de penalidade de esparsidade<sup>4</sup>;  $f(\mathbf{X})$  é um termo de discriminação imposto aos coeficientes da matriz  $\mathbf{X}$ ; e  $\lambda_1$  e  $\lambda_2$  são parâmetros escalares que controlam a influência da penalidade de esparsidade e do termo de discriminação.

A restrição  $\|\mathbf{d}_n\|_2 = 1$  implica que a norma- $\ell^2$  de cada átomo  $\mathbf{d}_n$  em  $\mathbf{D}$  seja unitária<sup>5</sup>, garantindo que os átomos tenham o mesmo peso na reconstrução. No caso contrário, a norma- $\ell^2$  de  $\mathbf{D}$  pode ser arbitrariamente grande, resultando em soluções triviais da matriz de coeficientes  $\mathbf{X}$ .

O primeiro termo  $r(\mathbf{A}, \mathbf{D}, \mathbf{X})$  está associado com as capacidades discriminativas de representação esparsa do dicionário. Com objetivo de apresentar formalmente esse termo, uma série de definições preliminares devem ser discutidas. Primeiro,  $\mathbf{X}_i$  pode ser escrito como  $\mathbf{X}_i = [\mathbf{X}_i^1; \dots; \mathbf{X}_i^j; \dots; \mathbf{X}_i^M]$ , em que  $\mathbf{X}_i^j$  são os coeficientes de representação de  $\mathbf{A}_i$  sobre  $\mathbf{D}_j$ . Adicionalmente,  $\mathbf{R}_k = \mathbf{D}_k \mathbf{X}_i^k$  é a representação por  $\mathbf{D}_k$  de  $\mathbf{A}_i$ . Antes de tudo, o dicionário  $\mathbf{D}$  deve representar bem  $\mathbf{A}_i$ , ou seja  $\mathbf{A}_i \approx \mathbf{D}\mathbf{X}_i = \mathbf{D}_1 \mathbf{X}_i^1 + \dots + \mathbf{D}_i \mathbf{X}_i^i + \dots + \mathbf{D}_M \mathbf{X}_i^M = \mathbf{R}_1 + \dots + \mathbf{R}_i + \dots + \mathbf{R}_K$ , sendo  $\mathbf{R}_i = \mathbf{D}_i \mathbf{X}_i^i$ . Em seguida, posto que o subdicionário  $\mathbf{D}_i$  está associado a  $i$ -ésima classe, é esperado que  $\mathbf{A}_i$  possa ser representado adequadamente por  $\mathbf{D}_i$  mas não por  $\mathbf{D}_j$ , considerando  $j \neq i$ . Essa condição implica que  $\mathbf{X}_i^i$  deve ter coeficientes significativos de modo que  $\|\mathbf{A}_i - \mathbf{D}_i \mathbf{X}_i^i\|_F^2$  seja pequeno, enquanto  $\mathbf{X}_i^j$  deve ter coeficientes próximos de zero de forma que  $\|\mathbf{D}_j \mathbf{X}_i^j\|_F^2$  seja pequeno<sup>6</sup>.

Dessa forma, pode-se definir o termo de finalidade de discriminação como:

$$r(\mathbf{A}_i, \mathbf{D}, \mathbf{X}) = \|\mathbf{A}_i - \mathbf{D}\mathbf{X}_i\|_F^2 + \|\mathbf{A}_i - \mathbf{D}_i \mathbf{X}_i^i\|_F^2 + \sum_{j=1, j \neq i}^K \|\mathbf{D}_j \mathbf{X}_i^j\|_F^2. \quad (16)$$

Em outras palavras,  $r(\mathbf{A}_i, \mathbf{D}, \mathbf{X}_i)$  contém três termos de penalidade, ilustrados na Figura 13a. O primeiro,  $\|\mathbf{A}_i - \mathbf{D}\mathbf{X}_i\|_F^2$ , impõe que  $\mathbf{D}$  represente  $\mathbf{A}_i$  adequadamente. Assim, um sinal de qualquer classe pode ser reconstruído por meio do dicionário e seu respectivo vetor esparso de coeficientes. Entretanto, mesmo que essa condição esteja garantida,  $\mathbf{R}_i$  pode desviar-se significativamente de  $\mathbf{A}_i$ , fazendo com que  $\mathbf{D}_i$  não possa

<sup>4</sup>O significado de esparsidade se refere à condição em que ao se combinar linearmente os átomos para representar uma amostra de sinal, muito dos coeficientes devem ser zero ou muito próximos de zero (Zhang et al., 2015).

<sup>5</sup>O conceito de norma está relacionado à distâncias, em geral é uma função que atribui um escalar real não-negativo a um vetor em um espaço vetorial. Especificamente  $\|\cdot\|_2$  é o operador de norma  $\ell_2$ , também chamado de distância Euclidiana. Outros exemplos conhecidos são: o operador de norma  $\ell_1$  também chamado de distância de Manhattan ( $\|\cdot\|_1$ ) e o operador de norma  $\ell_0$  ou pseudo-norma ( $\|\cdot\|_0$ ), que indica a cardinalidade do vetor (número de elementos não nulos).

<sup>6</sup>A notação  $\|\cdot\|_F^2$  se refere à norma de Frobenius, usada quando a norma  $\ell_2$  é aplicada à matrizes.

representar  $\mathbf{A}_i$  bem. Uma maneira de atenuar esse problema é incluir um segundo termo de penalidade que impõe que  $\|\mathbf{A}_i - \mathbf{D}_i \mathbf{X}_i^i\|_F^2$  seja pequeno, ou seja, que a reconstrução do conjunto de uma classe a partir de dicionários específicos à classe tenha menor erro possível. Esse termo, embora melhore a representação, não garante que os outros dicionários também não apresentem reduzido erro de reconstrução de  $\mathbf{A}_i$ , suscitando em uma baixa capacidade discriminativa de  $\mathbf{D}$ . Para circunavegar essa limitação, o terceiro termo é incluído:  $\|\mathbf{D}_j \mathbf{X}_i^j\|_F^2$ . Com esse termo, a representação de  $\mathbf{D}_j$  para  $\mathbf{A}_i$ ,  $j \neq i$ , terá seus coeficientes minimizados. Portanto, o termo de fidelidade de discriminação atenderá todos os requisitos: ser esparsos e discriminativo<sup>7</sup>.

O termo de discriminação  $f(\mathbf{X})$ , por outro lado, reforça a separação entre as classes do problema. Esse termo é baseado no critério de discriminação de Fisher, cujo objetivo central é minimizar o espalhamento entre classes e maximizar o espalhamento intra classes de  $\mathbf{X}$ , denotados por  $\mathbf{S}_W(\mathbf{X})$  e  $\mathbf{S}_B(\mathbf{X})$ , respectivamente. Esses termos são formalmente definidos por:

$$\mathbf{S}_W(\mathbf{X}) = \sum_{i=1}^M \sum_{\mathbf{x}_k \in \mathbf{X}_i} (\mathbf{x}_k - \mathbf{m}_i)(\mathbf{x}_k - \mathbf{m}_i)^T, \quad (17)$$

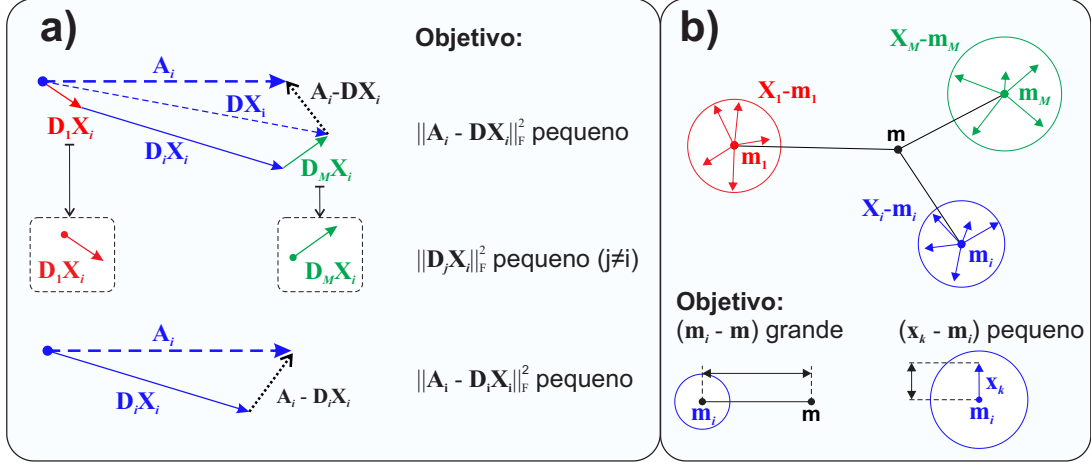
$$\mathbf{S}_B(\mathbf{X}) = \sum_{i=1}^M n_i (\mathbf{m}_i - \mathbf{m})(\mathbf{m}_i - \mathbf{m})^T, \quad (18)$$

onde  $\mathbf{m}_i$  e  $\mathbf{m}$  são os vetores médios de  $\mathbf{X}_i$  e  $\mathbf{X}$ , respectivamente, e  $n_i$  é o número de instâncias de  $\mathbf{A}_i$ .

O termo  $(\mathbf{x}_k - \mathbf{m}_i)$  representa a distância entre cada átomo e os coeficientes médios pertencentes a uma classe. O termo  $(\mathbf{m}_i - \mathbf{m})$ , em contrapartida, mede a distância entre o coeficiente médio obtido de cada dicionário específico à classe e os coeficientes médios do dicionário completo composto por todos os sub-dicionários. Esses termos são ilustrados na Figura 13b. Os termos  $\mathbf{S}_W$  e  $\mathbf{S}_B$  são matrizes cujos elementos das diagonais são a soma do espalhamento intra e entre classes de cada dimensão do espaço do vetor de coeficientes, respectivamente. Consequentemente, o traço dessas matrizes integram o espalhamento de todas as dimensões em um único valor, e portanto, o termo  $tr(\mathbf{S}_W(\mathbf{X})) - tr(\mathbf{S}_B(\mathbf{X}))$  pode ser usado como uma função objetivo, denotada por  $f(\mathbf{X})$ , que visa alcançar espalhamento intra-classe mínimo e espalhamento entre classes máximo. Um termo elástico  $\eta \|\mathbf{X}\|_F^2$  pode ser introduzido na função para fazer que  $f(\mathbf{X})$  seja mais

<sup>7</sup>Uma discussão mais aprofundada das restrições de esparsidade podem ser encontradas em Yang et al. (2014).

Figura 13: Interpretação geométrica do termo de fidelidade de discriminação  $r(\mathbf{A}, \mathbf{D}, \mathbf{X})$  (a) e as componentes de espalhamento intra e entre classes do termo de discriminação  $f(\mathbf{X})$  (b).



Fonte: Autoria própria

suave e convexo. Dessa forma, a função objetivo  $f(\mathbf{X})$  é definida como:

$$f(\mathbf{X}) = \text{tr}(\mathbf{S}_W(\mathbf{X})) - \text{tr}(\mathbf{S}_B(\mathbf{X})) + \eta \|\mathbf{X}\|_F^2. \quad (19)$$

Ademais, na função objetivo  $J(\mathbf{D}, \mathbf{X})$  do FDDL existe um termo de penalidade esparsa  $\|\mathbf{X}\|_1$ . O uso simultâneo de  $\|\mathbf{X}\|_F^2$  e  $\|\mathbf{X}\|_1$  pode fazer com que a solução de  $f(\mathbf{X})$  seja mais estável e esparsa ao mesmo tempo<sup>8</sup>.

Com o esquema proposto de FDDL, tanto os resíduos da representação de cada dicionário (erros de reconstrução) quanto os coeficientes do vetor esparsa de representação serão discriminativos, e portanto, podem ambos ser usados como informação sobre as classes para reconhecimento de padrões.

A partir do conjunto de dados  $\mathbf{A}$ , o algoritmo do FDDL aprende não apenas o dicionário desejado  $\mathbf{D}$ , mas também uma matriz de representação  $\mathbf{X}_i$  para cada classe cujas instâncias estão contidas em  $\mathbf{A}_i$ . Um vetor médio de coeficientes para cada classe ( $\mathbf{m}_i$ ), calculado pela média de cada vetor da matriz de representação  $\mathbf{X}_i$ , pode ser interpretado geometricamente como o centro da classe no espaço transformado gerado pelo espaço vetorial do dicionário  $\mathbf{D}$ . O dicionário específico a classe  $\mathbf{D}_i$  é forçado a representar as instâncias de treinamento, enquanto a matriz de vetores de coeficientes em  $\mathbf{X}_i$  é forçada a estar próximo de  $\mathbf{m}_i$  e distante de  $\mathbf{m}_j$  ( $j \neq i$ ). Considerando uma amostra de teste  $\mathbf{y}$  da classe composta por instâncias  $\mathbf{A}_i$ , os erros de reconstrução (resíduos) da representação

<sup>8</sup>Ibid.

por  $\mathbf{D}_i$  serão pequenos e o vetor esparsos de coeficientes sobre  $\mathbf{D}$  serão próximos de  $\mathbf{m}_i$ . Portanto, não apenas o erro de reconstrução, mas também os vetores médios de coeficientes  $\mathbf{m}_i$ , podem ser empregados como parâmetros para classificação.

Como o número de exemplos de treinamento por classe pode ser relativamente pequeno, o sub-dicionário aprendido  $\mathbf{D}_i$  pode não ser capaz de representar fielmente a instância de teste dessa classe, então, a amostra deve ser melhor representada pelo dicionário completo  $\mathbf{D}$ . Portanto, a representação global do modelo pode ser usado, definida por:

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \|\mathbf{y} - \mathbf{D}\boldsymbol{\alpha}\|_2^2 + \gamma \|\boldsymbol{\alpha}\|_p, \quad (20)$$

onde  $\hat{\boldsymbol{\alpha}} = [\hat{\boldsymbol{\alpha}}_1, \hat{\boldsymbol{\alpha}}_2, \dots, \hat{\boldsymbol{\alpha}}_K]$  e  $\hat{\boldsymbol{\alpha}}_i$  são os sub-vetores de coeficientes associados ao sub-dicionário  $\mathbf{D}_i$ .

Em suma, se  $\mathbf{y}$  pertence à classe  $i$ , o resíduo  $\|\mathbf{y} - \mathbf{D}_i\hat{\boldsymbol{\alpha}}_i\|_2^2$  deve ser pequeno, enquanto  $\|\mathbf{y} - \mathbf{D}_j\hat{\boldsymbol{\alpha}}_j\|_2^2$ ,  $j \neq i$  deve ser grande. Ademais, o vetor de representação  $\hat{\boldsymbol{\alpha}}$  deve estar próximo de  $\mathbf{m}_i$  mas longe da média dos vetores das demais classes, i.e.:

$$e_i = \|\mathbf{y} - \mathbf{D}_i\hat{\boldsymbol{\alpha}}_i\|_2^2 + w \|\hat{\boldsymbol{\alpha}} - \mathbf{m}_i\|_2^2. \quad (21)$$

onde  $w$  é um fator de ponderamento que faz o balanço entre a contribuição dos dois termos. O termo de erro  $e_i$  calculado para cada classe é um compromisso entre os resíduos da reconstrução e a distância entre o vetor de coeficientes da amostra e o vetor médio  $\mathbf{m}_i$ . Portanto, como os sub-dicionários específicos à classe são treinados para melhor representarem as amostras pertencentes de sua classe, o sinal  $\mathbf{y}$  é atribuído à classe  $id(\mathbf{y})$  cujo sub-dicionário provém melhor similaridade de representação, i.e.:

$$id(\mathbf{y}) = \arg \min_i \{e_i\}. \quad (22)$$

De maneira análoga aos métodos tradicionais, é como se essas informações da representação esparsa fossem as características usadas na entrada do classificador, porém criadas de modo supervisionado a partir de um conjunto de treinamento. Outra diferença é que características são projetadas para apresentar separabilidade por qualquer hiperplano, os parâmetros citados anteriormente, que representam quão bem a instância se encaixa em cada dicionário, não são separados por um hiperplano, mas por um operador de argumento mínimo. Portanto, os parâmetros não precisam estar em um *locus* específico no espaço

de características, já que a classificação é feita considerando a qual dicionário a instância mais se aproxima.

### 3.4 CONCLUSÃO


O método FDDL não requer uma etapa de extração de características desacoplada à etapa de classificação. Apesar da busca manual por características ser o método mais recorrente em processamento de sEMG, acredita-se que as técnicas de representações esparsas possam apresentar resultados semelhantes ou superiores com a vantagem de ser um procedimento monolítico, dispensado uma etapa de busca exaustiva pela melhor combinação de características. Ainda, o dicionário usado para classificar o sinal também pode ser empregado para compactá-lo e reconstruí-lo. O próximo capítulo descreve a metodologia utilizada na coleta de dados que compõe a base avaliada e no processamento dos sinais.



## 4 METODOLOGIA

A metodologia é dividida em etapas, estando resumidas de forma esquemática na Figura 14. Após definir um protocolo experimental os dados são coletados usando um *hardware* acoplado ao animal. Os dados de sEMG coletados são pré-processados digitalmente e então são segmentados para obter os dados relativos a cada movimento mastigatório dos quais as características são extraídas e usadas como entradas dos classificadores. Cada etapa será detalhada a seguir.

**Figura 14: Diagrama em blocos do processamento de sinais.**



**Fonte: Autoria própria**

### 4.1 PROTOCOLO EXPERIMENTAL

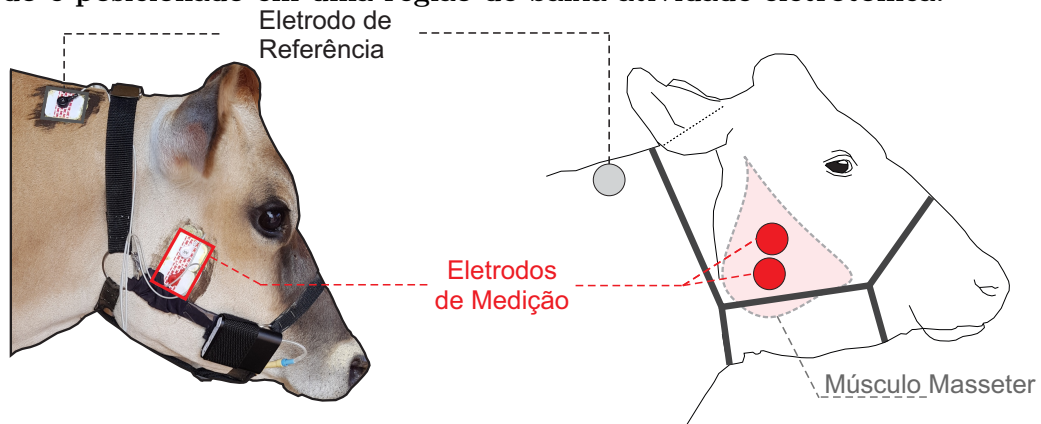
O experimento foi conduzido no Instituto Agrônomo do Paraná (IAPAR), em Pato Branco (Brasil) e foi aprovado pelo Comitê de Ética de Uso Animal (CEUA) da UTFPR<sup>1</sup>.

Os testes envolveram duas vacas Jersey pesando 380 e 460 kg no período do experimento<sup>2</sup>. Cada animal foi confinado e privado de alimento por 3 horas nas estações

<sup>1</sup>Protocolo 2015-002 / CEUA-UTFPR

<sup>2</sup>Um terceiro animal foi investigado, porém foi excluído do experimento por uma falha durante o experimento (deslocamento do eletrodo de Ag/AgCl), o que comprometeu severamente a qualidade dos dados.

**Figura 15: Localização dos eletrodos de sEMG no bovino. Dois eletrodos bipolares são posicionados sobre a pele, acima da região do músculo masseter e um terceiro eletrodo é posicionado em uma região de baixa atividade eletrotônica.**



**Fonte: Autoria própria**

de alimentação. Após esse período, a região do músculo masseter foi identificada e tricotomizada e limpa para fixação dos eletrodos de superfície (Eletrodos descartáveis 3M - 2223 de Ag/AgCl). Gel eletrolítico condutivo foi aplicado na região para melhorar o contato da interface pele-eletrodo e reduzir a impedância da pele (TAM; WEBSTER, 1977).

As medidas de sEMG foram feitas utilizando apenas um canal de registro para interferir minimamente no comportamento animal. O procedimento de posicionamento dos eletrodos foi executado de acordo com as recomendações do protocolo de EMG de Superfície para Avaliação Não-Invasiva de Músculos (SENIAM) (HERMENS et al., 2000). Os eletrodos foram montados na configuração bipolar, ou seja, um par de eletrodos é alocado no músculo para realizar uma medida diferencial pelo sistema de aquisição. Cada eletrodo foi posicionado na porção média da região do masseter<sup>3</sup> e separado por uma distância em 20 mm entre si, alinhado com a direção da fibra muscular (LUCA, 1997). Um terceiro eletrodo de referência foi posicionado em uma região de baixa atividade eletrotônica. A região escolhida foi a porção cranial da região dorsal-cervical. A alocação dos eletrodos de sEMG na cabeça do bovino é ilustrada na Figura 15. Os eletrodos foram conectados por cabos individuais no sistema de aquisição.

Silagem de milho foi escolhido como amostra de alimento pela fácil disponibilidade e oferecido em porções únicas de 7,340 e 6,365 kg para cada animal. O restante do alimento não consumido foi pesado e o consumo total líquido foi calculado, totalizando 6,915 e 6,365 kg. Após o consumo de silagem, aguardou-se até que o animal iniciasse a

<sup>3</sup>Uma figura mais detalhada da anatomia do masseter é apresentada no Apêndice B.

ruminação, até seu término. O comportamento animal foi continuamente rotulado por inspeção visual através de registros de vídeo.

## 4.2 AQUISIÇÃO DE EMG

O sistema embarcado de aquisição é mostrado na Figura 16, composto por uma Interface Analógica (AFE) ADS1298ECGFE-PDK baseada no amplificador Texas Instruments™ ADS1298, o qual é uma solução completa para aquisição de biopotenciais que provê interface de comunicação serial que é conectado a uma placa de desenvolvimento contendo um microcontrolador Texas Instruments™ MSP432 e um dispositivo de armazenagem *Secure Digital* (SD) (GOMES et al., 2017).

O kit de desenvolvimento MSP432 emprega um microcontrolador de baixa potência MSP432P401R, o qual possui uma Unidade de Processamento Central (CPU) de 32-bits ARM® Cortex-M4F operando em 48 MHz com 256 kBytes de memória flash e 64 kBytes de Memória de Acesso Aleatório Estática (SRAM). Um cartão de memória microSD de 4 GB foi usado para armazenar os dados coletados em formato de arquivo baseado em sistema *File Allocation Table* 32-bits (FAT32).

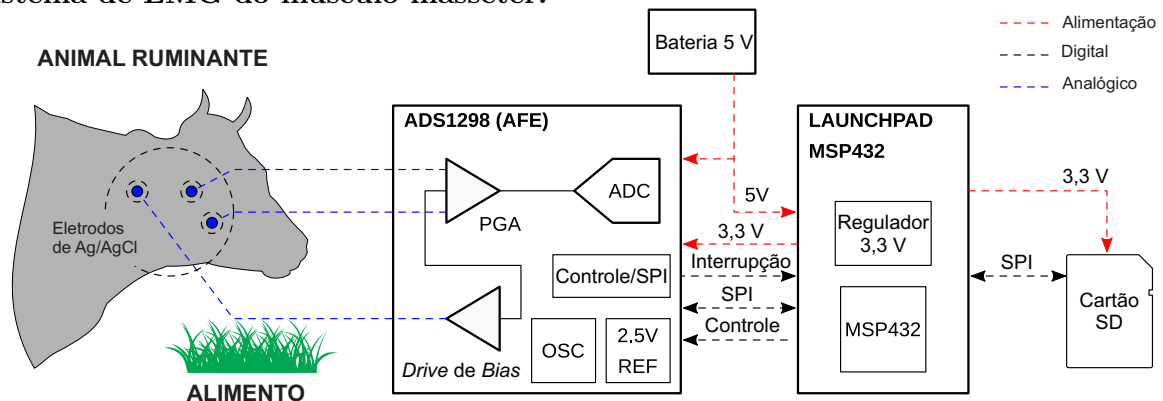
O ADS1298 e o cartão SD são conectados no microcontrolador por meio de barramento de Interface Serial Periférica (SPI). O ADS1298 é um circuito integrado monolítico projetado para medidas de biopotenciais, o qual possui um Amplificador de Ganho Programável (PGA) integrado com Razão de Rejeição de Modo Comum (CMRR) de -115 dB em 60 Hz, capaz de amplificar o sinal de EMG em até 12 vezes; um amplificador de polarização<sup>4</sup> (*bias*); um Conversor Analógico-Digital (ADC) delta-sigma de 24 bits, o qual pode amostrar o sinal em até 32000 amostras/segundo; e gerador de referência e oscilador internos. O algoritmo embarcado configura e controla a interface analógica e gerencia o sistema de arquivos FAT, o qual armazena os dados no cartão de memória *flash* SD. Uma bateria de 3,7 V e 5000 mAh de capacidade fornece alimentação para o sistema. A faixa de tensão de alimentação é usada pela AFE para gerar a referência de tensão e por um regulador de tensão de 3,3 V da placa do MSP432 para gerar o nível digital.

O sinal de EMG do músculo masseter é transduzido por um par de eletrodos convencionais de Ag/AgCl, os quais são conectados nas entradas diferenciais do PGA. O AFE foi parametrizado para um ganho de 6 vezes e para fazer aquisição a uma taxa de amostragem de 2 kSPS, o que resulta em uma saída de dados com uma largura de banda

---

<sup>4</sup>Condicionador de referência, também é conhecido como Condicionador de Referência (RDL) devido a sua aplicação na perna direita em medidas de eletrocardiografia.

**Figura 16: Diagrama simplificado do sistema embarcado utilizado na aquisição do sistema de EMG do músculo masseter.**



Fonte: Gomes et al. (2017)

de 524 Hz.


O *drive de bias* amostra tensões de modo comum da superfície da pele, amplifica e condiciona o sinal invertido para o corpo do animal por meio de um terceiro eletrodo posicionado na região da extremidade da mandíbula. Essa realimentação promove cancelamento de ruído de modo comum e aterramento. A magnitude do cancelamento de ruído é proporcional ao ganho do *drive de bias* (WINTER; WEBSTER, 1983), ajustado por um resistor externo conectado nos terminais da AFE. O capacitor de realimentação é conectado à AFE no laço do *drive de bias* (operando como um circuito integrador) para melhorar a estabilidade. A rotina de interrupção digital dispara quando um novo dado está pronto para ser transferido. O microcontrolador continuamente acumula os dados e armazena em um formato apropriado no cartão SD de modo que o arquivo possa ser importado para um *software* em um computador para ser processado e analisado.

#### 4.3 PRÉ-PROCESSAMENTO

Após o registro da atividade miográfica, o sinal de sEMG foi transferido para um computador para tratamento dos dados. O Sinal foi filtrado digitalmente, normalizado e rotulado.

No espectro de frequência do sinal de EMG, a componente que prevalece é a de 60 Hz, sendo maior que o próprio sinal. Isso ocorre devido as interferências da rede de energia elétrica. Para corrigir o problema, o ruído da rede foi atenuado por filtro Notch de Resposta Infinita ao Impulso (IIR) em 60 Hz com fator de qualidade (Q) de 50, atenuando pontualmente a frequência indesejada. Um filtro passa-banda IIR (Butterworth) de quarta

ordem foi projetado para selecionar a banda de interesse de sinais eletromiográficos, a qual se situa entre as frequências de 10 e 500 Hz, ou seja, frequências fora dessa faixa foram atenuadas. Essa filtragem foi realizada posteriormente à coleta por um algoritmo de filtragem digital<sup>5</sup>. A Figura 17 ilustra o processo de filtragem de um sinal real de EMG.



Fonte: Adaptado de Clark et al. (1992)

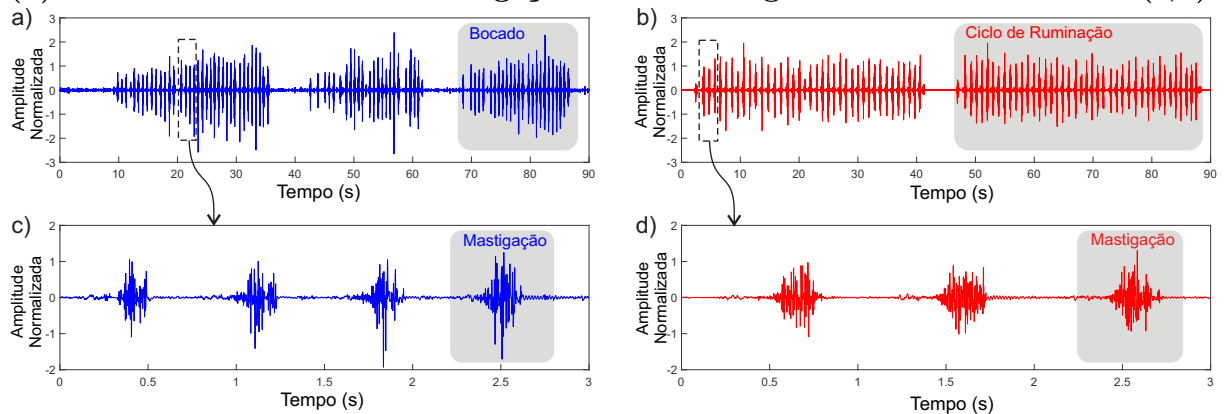
Como o sinal de sEMG é dependente das condições experimentais durante a coleta como posição dos eletrodos, temperatura corporal e características individuais, é necessário que o dado seja normalizado, ou seja, esteja dentro de uma faixa invariante de valores. A normalização de sinais de sEMG em humanos é geralmente feita pedindo para o indivíduo realizar a máxima contração voluntária do músculo em estudo. Dessa forma o sinal é representado como uma fração da máxima contração voluntária. Entretanto, é trabalhoso induzir esse procedimento em animais ruminantes. Portanto, adotou-se um protocolo alternativo de normalização baseado na estatística global dos sinais coletados.

Os dados foram normalizados pela amplitude do sinal. O procedimento consistiu em retificar o sinal e encontrar os picos que eram maiores que 10% do sinal máximo da série temporal de todo o sinal, separados por um período de ao menos 1 segundo. Então, o sinal foi dividido pelo valor do percentil 95 da amplitude dos picos identificados para cada animal individualmente. Assim os dados de eletromiografia são representados como uma fração dos valores máximos daquele animal investigado na condição experimental em que os dados foram coletados.

Os eventos mastigatórios foram rotulados por inspeção durante cada período de atividade dividido em consumo, ruminação e ócio. A atividade de consumo foi definida como o período no qual o animal estava ingerindo a silagem, incluindo bocados, mastigações e deglutição. Alguns eventos anômalos, como movimentos de cabeça e língua, são considerados nesse período pela indissociabilidade com os movimentos mastigatórios. A ruminação compreende o período entre o retorno do *bolus* ruminal, os sucessivos ciclos

<sup>5</sup>Todas as análises a partir dessa etapa foram feitas *off-line*, embora muitas análises que serão discutidas na sequência visam a viabilização do processamento *on-line*.

**Figura 18: Sinal eletromiográfico durante 90 segundos de consumo (a) e ruminação (b) e detalhamento de uma mastigação durante 3 segundos de cada atividade (c,d).**



**Fonte: Autoria própria**

mastigatórios e a deglutição. O ócio foi definido como o período em que o animal não estava mastigando, incluindo eventos anômalos. Exemplos de sequências de bocados durante o consumo e períodos de ruminação dentro de um intervalo de 90 segundos são mostrados na Figura 18a e Figura 18b, respectivamente. O sinal dos movimentos mastigatórios individuais de cada classe (consumo e ruminação) são mostrados ao longo de um intervalo de 3 segundos nas Figura 18c e Figura 18d, respectivamente.

É possível observar que apesar de sua semelhança, as atividades possuem particularidades. Embora essas diferenças sejam praticamente indiscrimináveis ao olhar humano não treinado, esses padrões podem ser reconhecidos por técnicas computacionais de aprendizado de máquina. Vale ressaltar que nesse trabalho os padrões são classificados a partir da informação obtida de um único movimento mastigatório, desconsiderando os aspectos de dependência temporal. Esse padrão pode ser mais facilmente reconhecido visualmente, vide Figura 18a e Figura 18b. Entretanto, o treinamento e validação de modelos de reconhecimento de sequências temporais, como os Modelos Ocultos de Markov (HMM), dependem de um grande volume de dados obtidos de diversas séries completas de consumo e ruminação. Portanto essa abordagem não é tratada nesse trabalho embora seja uma hipótese promissora ainda não avaliada.

Após obter o sinal filtrado e normalizado deve-se segmentar o sinal, separando cada movimento individual de mastigação. Esse procedimento fornece a informação de contagem de movimentos musculares, frequência dos movimentos e identificação de períodos de repouso. Além disso, os eventos de uma determinada atividade muscular podem ser analisadas separadamente, sendo possível extrair informação não só de um período, mas de cada movimento individual.

#### 4.4 SEGMENTAÇÃO

Como o animal não mastiga em intervalos necessariamente regulares, a série temporal do sinal de sEMG precisa ser segmentada em janelas que contenham apenas trechos de sinal relativo ao evento mastigatório. O método de segmentação também deve preferencialmente remover respostas eletromiográficas de movimentos não-mastigatórios e sinais anômalos que possam acontecer durante os períodos de consumo e ruminação.

Um dos métodos mais tradicionais para segmentação *offline* é baseado na identificação do início da ativação muscular por limiar, chamado de *onset* (STAUDE et al., 2001). O método, ilustrado na Figura 19a, consiste em retificar e suavizar<sup>6</sup> o sinal e então aplicar um critério de limiar ( $x_{Th}$ ) baseado na linha base do sinal para identificar o início (*onset*) e final (*offset*) da contração muscular. O *onset* é o instante de tempo em que o sinal ultrapassa o limiar ( $W_{onset} = arg(x_i > x_{Th})$ ) e o (*offset*) quando a amplitude se torna novamente menor que o limiar ( $W_{offset} = arg(x_i < x_{Th})$ ). O período do sinal ( $T$ ) é definido pela janela de tempo entre esses dois instantes ( $W_{offset} - W_{onset}$ ). Períodos menores que um valor crítico ( $W_{crit}$ ) são excluídos considerando que sinais de curta duração ocorrem devido a artefatos e movimentos anômalos. O limiar é definido a partir da média da linha base ( $\mu_{BL}$ ) e seu desvio padrão ( $\sigma_{BL}$ ) como :

$$limiar = \mu_{BL} + k\sigma_{BL}, \quad (24)$$

onde  $k$  é uma variável pré-definida que ajusta o nível do limiar (SOLNIK et al., 2010).

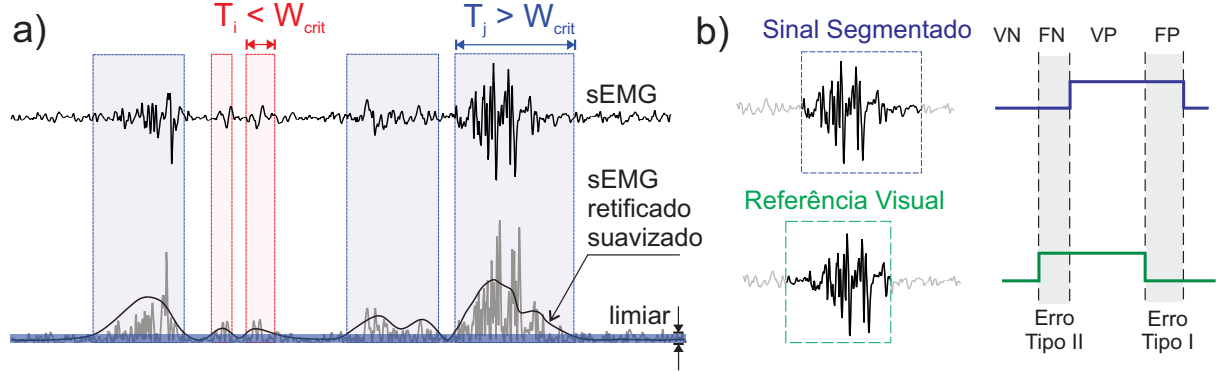
Como dois limiares são aplicados para definir um segmento (amplitude e período mínimos), esse método é chamado de Segmentação por Limiar Duplo (DTOS). Os limites identificados da janela são usados para definir os segmentos a serem analisados. Cada vetor de segmento de série temporal de sEMG é armazenado como uma instância de mastigação. A suavização é realizada pela convolução do sinal com uma janela. A janela crítica é definida como 100 ms, visto que foi observado que sinais mastigatórios dificilmente tem duração menor que esse período.

Para definir a dimensão ótima da janela de suavização e limiar, o sinal de sEMG foi analisado por inspeção visual com base nas recomendações de Hodges e Bui (1996). O sinal analisado visualmente foi montado pela composição de diferentes trechos dos dados coletados, totalizando 15 minutos e 787 períodos mastigatórios.

---

<sup>6</sup>O conceito de suavizar é o mesmo que aplicar uma filtragem de altas frequências.

Figura 19: Processo do método de segmentação (a) e avaliação (b). O sinal é retificado e suavizado por média móvel. O limiar é aplicado para identificar o período de contração muscular. Se o período ( $T$ ) é maior que um valor crítico ( $W_{crit}$ ), o segmento é armazenado. A avaliação é baseada na comparação entre os períodos detectados pelo método proposto e identificados visualmente.



Fonte: Autoria própria

A Figura 19b ilustra o processo de avaliação, que é baseado na comparação dos períodos identificados visualmente e dos período selecionados pelo método DTOS. Os períodos de mastigação determinados por inspeção visual e segmentação automática foram transformados em um vetor binário, onde 1 corresponde à presença de movimento mastigatório e 0 à ausência. A performance foi calculada pelas métricas de contingência: Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN). O erro foi definido como a fração de amostras atribuídas incorretamente, o que é equivalente à soma de FN e FP dividido pelo número total de amostras. A taxa de cada erro pode ser definida como Taxa de Falsos Negativo (TFN), conhecido como erro do Tipo II, Taxa de Falsos Positivos (TFP), conhecido como erro do Tipo I, Taxa de Verdadeiros Positivos (TVP), chamado de sensibilidade e Taxa de Verdadeiros Negativos (TVN), também chamado de especificidade. Essas métricas são calculadas por:

$$TFN = FN / (FN + VP), \quad (25)$$

$$TFP = FP / (FP + VN), \quad (26)$$

$$TVP = VP / (VP + FN), \quad (27)$$

$$TVN = VN / (VN + FP). \quad (28)$$

Uma série de valores de dimensão da janela de suavização e do valor  $k$  do limiar foram avaliados usando o erro como métrica de avaliação. Os parâmetros foram ajustados com objetivo de minimizar o erro e maximizar a semelhança entre a distribuição dos



períodos visual e automaticamente determinados. Para determinar a semelhança entre as distribuições estatísticas dos períodos, utilizou-se uma métrica chamada de divergência de Kullback-Leibler, a qual avalia quantitativamente a diferença entre duas funções de densidade de probabilidade.

Uma Função de Densidade de Probabilidade (PDF), que é função de distribuição de probabilidade para uma variável contínua, foi ajustado para o histograma de períodos usando um Modelo de Mistura Gaussiana (GMM). Os coeficientes foram parametrizados para maximizar a verossimilhança pelo algoritmo de maximização de esperança estatística de acordo com o seguinte modelo (BISHOP, 2006)

$$g(x) = c_1 g_1(x) + c_2 g_2(x) = \frac{c_1}{\sigma_1 \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{x-\mu_1}{\sigma_1} \right)^2} + \frac{c_2}{\sigma_2 \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{x-\mu_2}{\sigma_2} \right)^2}, \quad (29)$$

onde  $c_1$  e  $c_2$  são as componentes de proporção de mistura,  $\mu_1$  e  $\mu_2$  são os valores médios de cada função e  $\sigma_1$  e  $\sigma_2$  os desvios padrão das funções. A escolha de dois componentes na mistura foi baseado na análise por inspeção visual do histograma dos períodos. A Divergência de Kullback-Leibler (KLD) foi usada para medir a disparidade dos modelos obtidos visualmente e automaticamente. O KLD é uma medida de diferença entre duas distribuições de probabilidade  $P(x)$  e  $Q(x)$  no domínio  $\chi$ , definido como:

$$D_{KL}(P||Q) = - \sum_{x \in \chi} P(x) \log \left( \frac{Q(x)}{P(x)} \right). \quad (30)$$

Assim, o KLD foi usado como uma métrica para selecionar os parâmetros de segmentação entre aqueles com menores erros.

Por fim, como o aprendizado de dicionário requer amostras de tamanho fixo, a janela deve ser limitada. Os limites da janela fixa foi definido começando em  $W_i = W_{onset} - W_{bw}$  e terminando em  $W_o = W_{onset} + W_{fw}$ . Os parâmetros  $W_{bw}$  e  $W_{fw}$  são períodos anteriores e posteriores ao *onset*, definidos pela avaliação visual do sinal de EMG. A janela variável, obtida pelo método DTOS, começa em  $W_i = W_{onset}$  e termina em  $W_o = W_{offset}$ , definidos pelo limiar.

As características foram extraídas tanto do período definido pelo DTOS (janela variável) quanto pela janela limitada (janela fixa).

## 4.5 EXTRAÇÃO DE CARACTERÍSTICAS

Os sinais de sEMG e seus atributos são extensivamente investigados para uso clínico e em engenharia. Dentre várias aplicações estão os diagnósticos automáticos e controle de próteses robóticas. Entretanto, o maior problema é a dificuldade de classificação, pois sua baixa amplitude somada aos ruídos de origem desconhecida, tornam o sinal complexo (KEMSLEY et al., 2003).

A extração de características é um conjunto de técnicas que consistem em transformar o sinal bruto de EMG em um conjunto de atributos representativos, chamado vetor de características. Uma extração adequada deve representar aspectos intrínsecos do músculo e descartar informações irrelevantes (ZARDOSHTI-KERMANI et al., 1995). Portanto, uma classificação robusta do sinal de sEMG depende da seleção correta das características a serem extraídas. Como o sinal de EMG é composto por uma sobreposição de MUAPs disparados de maneira irregular, essa representação pode acontecer no domínio do tempo e da frequência (OSKOEI; HU, 2007).

Doze métodos não-supervisionados de extração de características no domínio do tempo foram implementadas. Sete foram selecionadas para estimar amplitude e potência. Quatro são comumente usadas na literatura: Valor Médio Absoluto (MAV), também chamado de Integral do Valor Absoluto (IAV); Média Quadrática (RMS); Variância (VAR); e Comprimento da Forma de onda (WL) (PHINYOMARK et al., 2012). Três delas foram recentemente propostas na literatura: Diferença Absoluta do Valor de Desvio Padrão (DASDV) (PHINYOMARK et al., 2014); Valor Médio da Raíz Quadrada (MSR) (SAMUEL et al., 2018); e Escala-L (LS) (HOSKING, 1990). Ainda três são características contendo informação de frequência: Amplitude Willison (WAMP), Mudança do Sinal de Inclinação (SSC); e Cruzamento por Zero (ZC). Ainda são inclusas uma característica que mede complexidade não-linear: a Máximo Comprimento Fractal (MFL); e outra baseada na modelagem de série-temporal: os Coeficientes Autorregressivos (AR) (PHINYOMARK et al., 2012). Para o AR, um modelo de coeficientes de sexta ordem foi empregado (AR6), o qual provém mais do que uma característica para cada segmento de sinal.

A partir dessas características, quatro conjuntos<sup>7</sup> foram implementados. Esses conjuntos foram selecionados de um trabalho recente onde oito conjuntos estado-da-arte e dois conjuntos propostos foram avaliados (PHINYOMARK et al., 2018). Dois

---

<sup>7</sup>Conjunto tem o significado de *multi-feature set*, ou seja, é o termo “conjunto de múltiplas características” elipsado.

dos conjuntos avaliados (MS1 e MS2) e dos conjuntos propostos (TD4 and TD9), os quais atingiram melhor performance, foram escolhidos para avaliação e comparação. O primeiro é o conjunto mais recorrente na literatura, chamado de conjuntos de características no domínio do tempo de Hudgins (MS1) (HUDGINS et al., 1993). O segundo é um melhoramento desse conjunto, o qual é uma combinação de MS1 com RMS e AR6 (MS2) (Yonghong Huang et al., 2005). Os conjuntos TD4 e TD9 são referidos como “o novo conjunto de quatro e nove características no domínio do tempo”. Esses dois últimos conjuntos mencionados foram determinados por um algoritmo de busca chamado Seleção Sequencial Crescente (SFS, do inglês *Sequential Forward Selection*). Os conjunto TD4 foi encontrado adicionando características até que o primeiro máximo local fosse encontrado onde uma melhoria significativa fosse observada. O conjunto TD9 por outro lado foi obtido procurando o maior desempenho global de classificação. Os conjuntos são compostos pelas seguintes características:

- MS1: MAV, WL, ZC, SSC (HUDGINS et al., 1993);
- MS2: MAV, WL, ZC, SSC, RMS E AR6 (Yonghong Huang et al., 2005);
- TD4: LS, MFL, MSR, WAMP (PHINYOMARK et al., 2018);
- TD9: LS, MFL, MSR, WAMP, ZC, RMS, IAV, DASDV, VAR (PHINYOMARK et al., 2018).

#### 4.6 CLASSIFICAÇÃO

A partir dos dados rotulados, duas classes foram definidas: consumo (alimentação) e ruminção. Os períodos de ócio não foram inclusos como uma classe separada pois em geral não há sinal de sEMG. Dessa forma, esses períodos devem ser identificados apenas pelo processo de segmentação. Sinais anômalos, que eventualmente ocorrem durante o período de ócio, frequentemente possuem amplitude relativamente menor aos sinais de mastigação, e dessa forma devem se estabelecer abaixo do limiar de segmentação, não sendo atribuídos como um sinal elegível à classificação.

Um total de 1000 instâncias de cada classe foram selecionadas aleatoriamente dos sinais coletados para compor a base de dados para avaliação, totalizando 2000 exemplos de segmentos de sEMG relativos à mastigação.

As características propostas foram extraídas dos segmentos da base de dados e classificadas utilizando uma técnica de aprendizado de máquina chamada Análise de

Discriminantes Lineares (LDA), que é uma generalização do discriminante Fisher o qual encontra uma combinação linear das variáveis de entrada que define um hiperplano de separação no espaço de características. Essa técnica, além de não depender de calibração de parâmetros, é computacionalmente eficiente para aplicações de tempo-real e sua performance na classificação de sinais eletromiográficos se equipara aos algoritmos mais complexos como Máquinas de Vetores de Suporte (SVM) e redes neurais (TKACH et al., 2010; PHINYOMARK et al., 2013).

O esquema de classificação utilizando a abordagem proposta (FDDL) é ilustrado na Figura 20. Um conjunto de treinamento é usado para treinar um dicionário ( $\mathbf{D}_i$ ) e encontrar uma matriz de coeficientes de representação ( $\mathbf{X}_i$ ) para cada classe (Figura 20a). Os átomos do dicionário podem ser vistos como um conjunto de componentes fundamentais do sinal, o quais são linearmente combinados pelo vetor de coeficientes para reconstruí-lo <sup>8</sup>.

A partir da matriz de coeficientes, obtém-se a média dos vetores de representação ( $\mathbf{m}_i$ ). Com objetivo de classificar um sinal de teste, cada dicionário é usado para calcular um vetor de coeficientes ( $\hat{\boldsymbol{\alpha}}_i$ ) por meio de codificação esparsa (Figura 20b). Esses vetores são usados para reconstruir o sinal a partir de cada dicionário específico à classe ( $\mathbf{D}_i \hat{\boldsymbol{\alpha}}_i$ ). O erro ( $e_i$ ) associado a cada classe é igual a uma soma ponderada dos resíduos de reconstrução, ou seja, a diferença entre o sinal original e o reconstruído, e diferença entre os vetores de coeficientes esparsos ( $\mathbf{m}_i$  e  $\hat{\boldsymbol{\alpha}}$ ). O sinal de teste é atribuído à classe cujo dicionário apresenta melhor compromisso entre baixo erro de reconstrução e semelhança entre os coeficientes de representação.

Todos os resultados de classificação foram obtidos por validação cruzada com 10 partições (*10-fold*). Ou seja, a base de dados foi dividida em 10 partes, de forma que 9 partes são usadas para treinar o classificador e a parte remanescente usada para testar. Esse procedimento é executado 10 vezes até que todas as partes tenham sido usadas para treino e teste. Assim, cada resultado na verdade é composto por uma série de 10 resultados da validação cruzada.

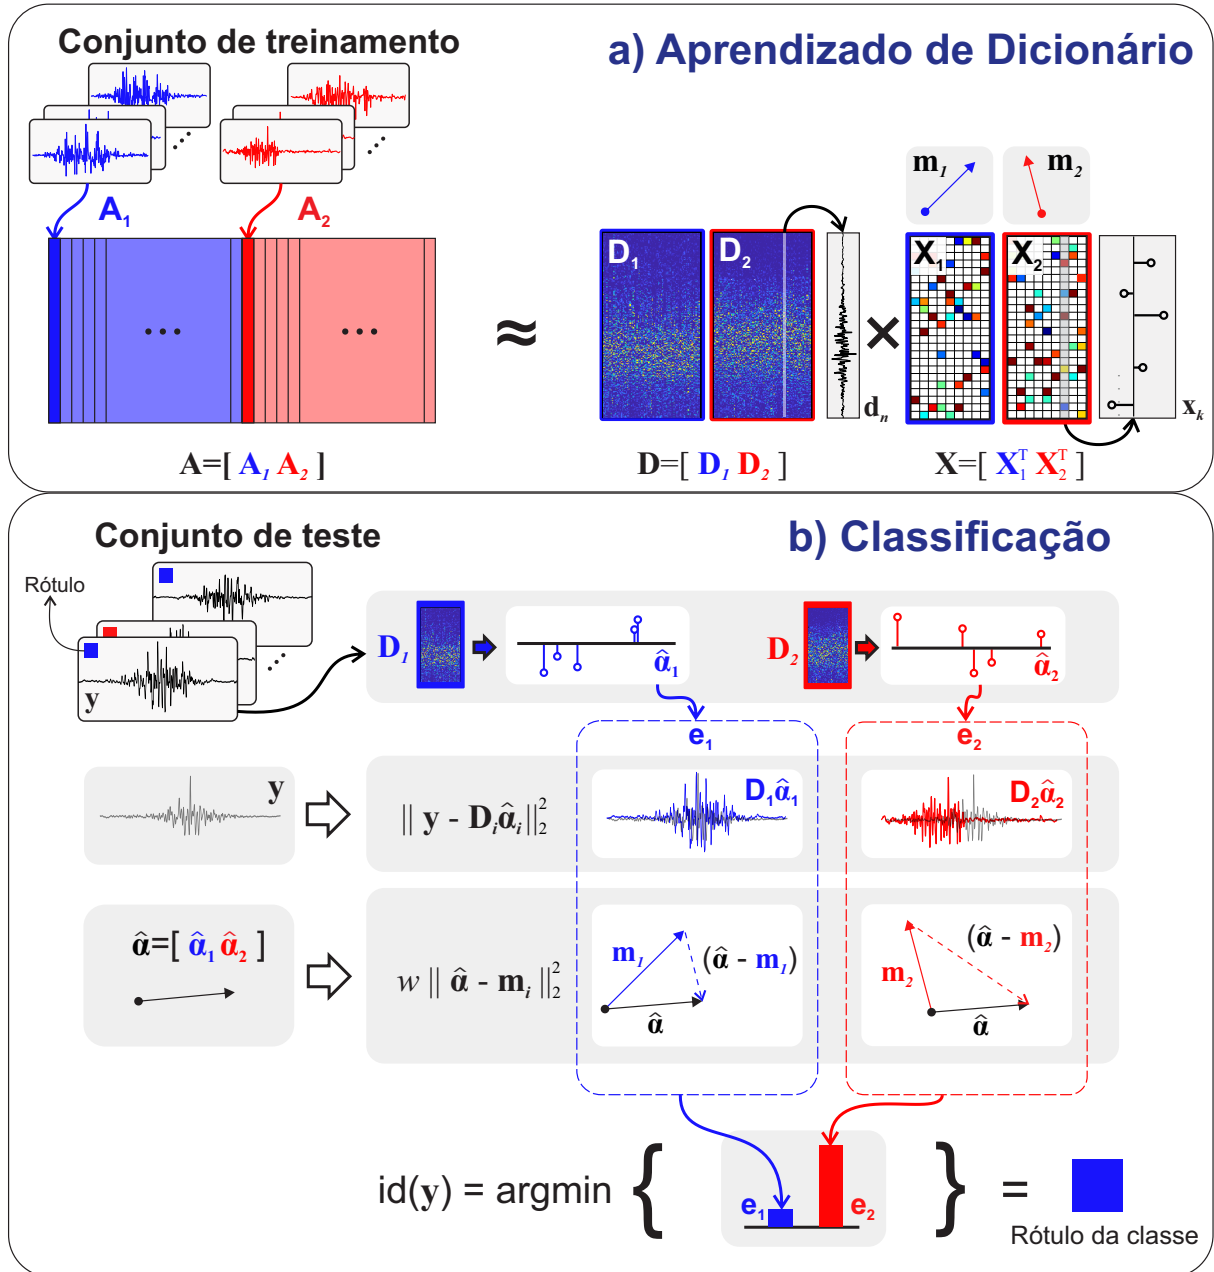
O teste da soma dos postos de Wilcoxon<sup>9</sup> foi aplicado nos resultados para verificar se a taxa de acertos usando características extraídas a partir de janela fixa e variável eram significativamente diferentes. Ainda, a performance do método proposto

---

<sup>8</sup>O princípio é similar à decomposição de sinais de EMG como uma soma de sequências de MUAPs (STASHUK, 2001), entretanto os *templates* dos MUAPs não terão necessariamente uma correspondência direta com os átomos dos dicionários

<sup>9</sup>Também conhecido como teste U de Mann-Whitney.

Figura 20: Metodologia de classificação usando o algoritmo FDDL. Um conjunto de treino é usado para aprender um dicionário e um matriz de coeficientes de representação para cada classe (a). O sinal é atribuído para a classe cujo dicionário apresenta menor erro de reconstrução e maior similaridade entre os vetores de representação (b).



Fonte: Autoria própria

(FDDL) foi avaliado alterando o tamanho de dicionário (número de átomos) e comparado com melhores resultados obtidos pelas técnicas de extração não-supervisionada<sup>10</sup> de características combinadas com LDA.

<sup>10</sup>Embora as técnicas de extração de características sejam não-supervisionada a classificação ainda é supervisionada.

## 4.7 CONCLUSÃO

A metodologia foi estipulada visando responder qual a técnica de segmentação e de extração de características mais adequadas. Além disso, pretende-se responder à hipótese de que técnicas de reconhecimento de padrões baseadas em aprendizado de dicionário possam substituir a convencional busca por parâmetros que representem os sinais de sEMG para finalidade de classificação. O próximo capítulo traz os resultados da avaliação dos métodos de segmentação, extração de características e classificação obtidos utilizando os dados coletados em animais.

## 5 RESULTADOS E DISCUSSÃO


Os resultados obtidos do método proposto de segmentação (DTOS) e classificação (FDDL) para essa aplicação são mostrados neste capítulo. A metodologia utilizada nesse trabalho derivou de resultados antecedentes em que outras técnicas foram avaliadas. Os resultados que antecedem os agora apresentados, e que serviram de guia para aprimorar a técnica proposta, se encontram no Apêndice C.

### 5.1 ANÁLISE QUALITATIVA

O histograma normalizado como função densidade de probabilidade do intervalo dos segmentos (tempo entre o final de uma mastigação e o começo da próxima) é mostrado na Figura 21. O histograma é dividido em ruminação e ingestão (consumo de silagem). A distribuição revela a ruminação como um processo mais lento (períodos mais longos de cerca de 600 ms a 1 segundo por mastigação) e uma variância menor, ou seja, uma atividade mais constante. Os *outliers* relativos às pausas durante a ruminação (cerca de 5 segundos) associados com a deglutição e retorno do *bolus* não são mostrados. O processo de consumo apresenta um espalhamento com maior variância e maiores períodos. A distribuição se estende de 400 ms segundos até 2 segundos com maior probabilidade em 600 ms. Pode-se inferir que durante o consumo o animal executa os movimentos de mastigação mais rapidamente porém com períodos mais inconstantes. A longa cauda da distribuição se alongando até 1 a 2 segundos estão relacionados às mastigações mais espaçadas no início do bocado. Esse resultado demonstra que a ruminação é um processo quase invariante.

A partir do método DTOS pode-se determinar a duração dos sinais de mastigação visto que esse método utiliza uma janela de tamanho variável. A Figura 22 mostra o histograma normalizado como função densidade de probabilidade da duração (período) dos segmentos extraídos. O histograma é dividido em ruminação e alimentação. Os dados mostram que a duração do movimento mastigatório durante o consumo é em geral

**Figura 21: Histograma normalizado como função densidade de probabilidade do período dos segmentos extraídos pela técnica FLPCS.**



**Fonte: Autoria própria**


mais lento que a ruminação com maior variância. Uma hipótese para esse fenômeno é que o alimento ofertado (silagem), por ser um alimento particulado, não requer grande carregamento biomecânico durante a apreensão e mastigação. Os bocados são provavelmente menores e mais rápidos do que seriam, por exemplo, durante a pastagem. Dessa forma, imagina-se que o comportamento eletromiográfico da ruminação deve ser muito parecido independente da maneira como o alimento é ofertado, porém deve apresentar variações durante o consumo (apreensão e mastigação) dependendo da forma como o alimento é ofertado e do seu conteúdo de fibra. Por exemplo, alimentos mais fibrosos e com menor conteúdo de água devem demandar maior esforço para atingir o tamanho de partícula necessário para deglutição.

## 5.2 MÉTODO DE SEGMENTAÇÃO

O método proposto de segmentação automática (DTOS) foi primeiramente avaliado pelo erro na detecção do sinal de interesse em relação à inspeção visual (vide Seção 4.4), variando o fator de limiar e janela de suavização (Equação 24). O fator do limiar ( $k$ ) foi variado entre valores de 0,25 a 10, os quais foram avaliados para janelas com dimensão de 10, 20, 30, 50, 100 e 150 ms. A Figura 23 mostra o erro de segmentação em função do fator de limiar. Cada curva representa o erro de segmentação para cada



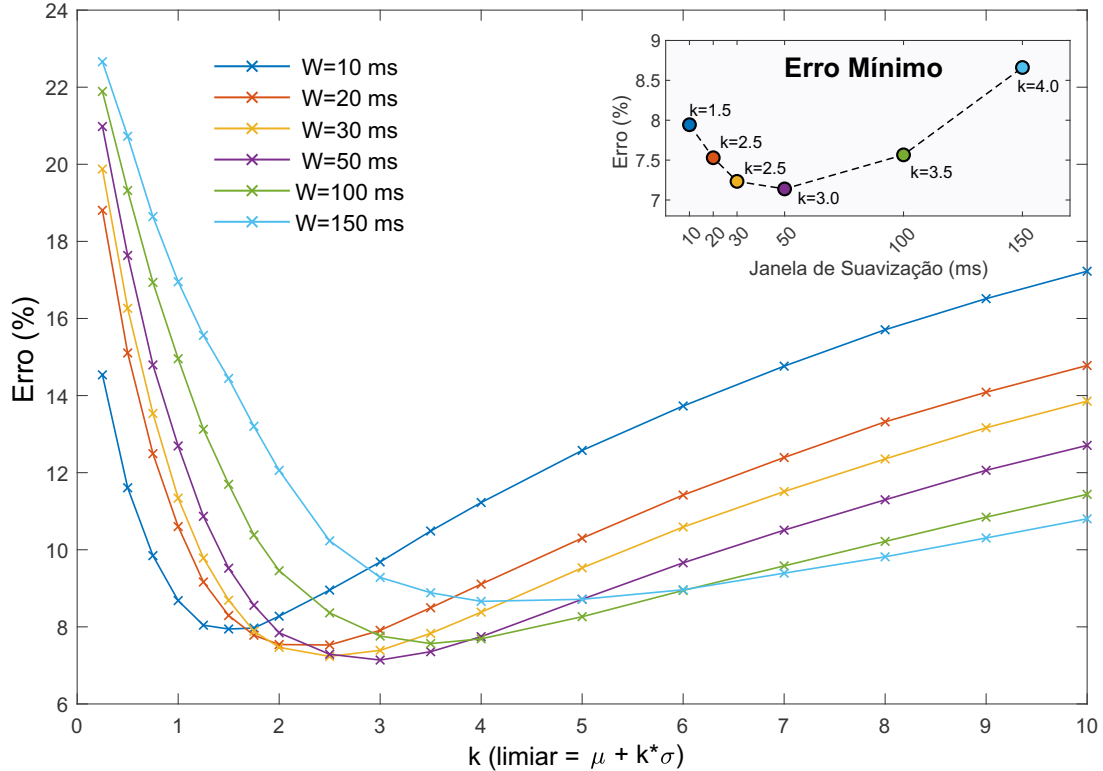
**Figura 22:** Histograma normalizado como função densidade de probabilidade da duração dos segmentos extraídos pela técnica DTOS.



**Fonte:** Autoria própria

janela de suavização. O gráfico interno (*insert*) mostra o erro mínimo encontrado para cada tamanho de janela e o respectivo valor de  $k$  que o minimiza.

**Figura 23:** Erro do método de segmentação automática (DTOS) em função do fator de limiar ( $k$ ) e janela de suavização. O gráfico interno mostra o menor erro encontrado para cada janela e o valor de  $k$  respectivo.

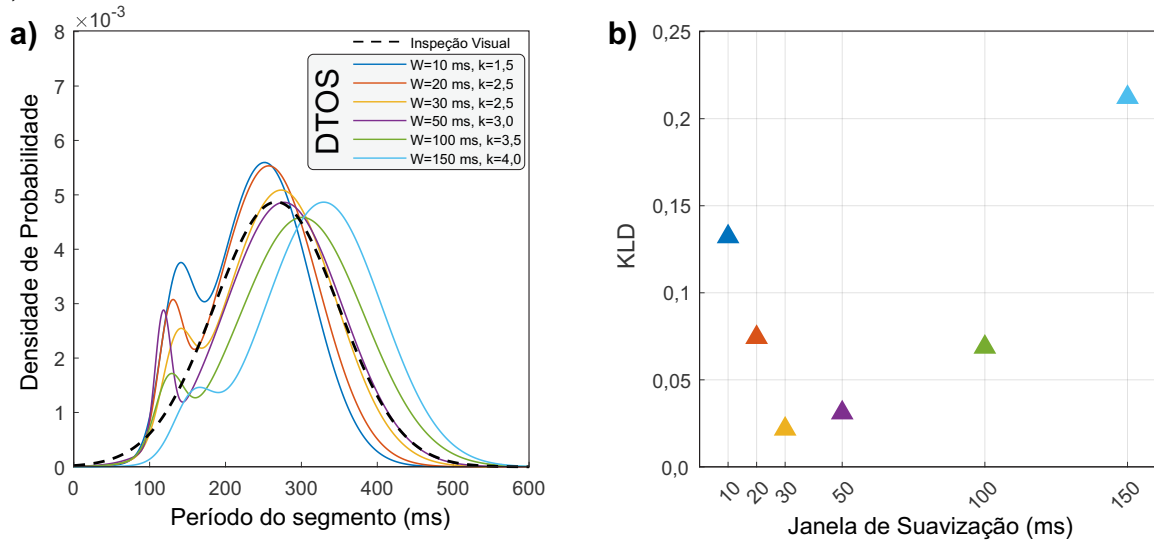


**Fonte:** Autoria própria

Erros podem estar relacionados com sinais rotulados erroneamente pelo especialista e a sinais que se situam abaixo do valor de limiar. Além disso, sinais anômalos (não-mastigatórios) são identificados automaticamente caso estejam acima do limiar. Ainda, os limites são definidos visualmente, então sempre existirá um trecho inicial que não será detectado até que atinja o limiar. Erros menores que 8% significam que 92% das amostras rotuladas visualmente está de acordo com o método automático. Vale ressaltar que isso não significa que 92% das mastigações serão detectadas corretamente pois o erro é calculado amostra por amostra, com resolução temporal de 0,5 ms.

Cada janela de suavização avaliada, juntamente com o limiar associado que leva ao menor erro, foram reavaliadas levando em consideração a distribuição probabilística do período obtido por esses parâmetros. O procedimento consiste em ajustar o GMM a partir da frequência (histograma) do período das janelas obtidos pelo método de segmentação. O GMM da segmentação automática ( $g^a(x)$ ) foi comparado com o GMM da referência visual ( $g^v(x)$ ) por meio da métrica KLD ( $D_{KL}(g^a(x)||g^v(x))$ , denotado como  $D_{KL}(g)$ ). A performance obtidas por cada parâmetro são detalhados na Tabela 14, onde as métricas

Figura 24: GMM do período do sinal de EMG segmentado por inspeção visual e pelo método DTOS (a). Divergência de Kullback-Leibler (KLD) entre os modelos (b).



Fonte: Autoria própria

de contingência (FNR, FPR, TPR, and TNR) e a KLD das distribuições ( $D_{KL}(g)$ ) são listadas.

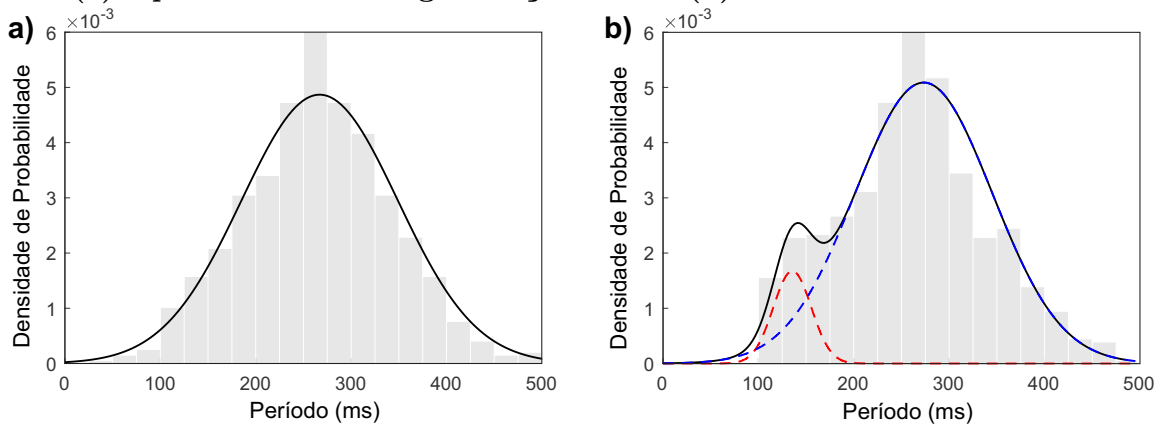
Tabela 14: Medidas de performance do método de segmentação com os pares de parâmetros que apresentaram menor erro.

W (ms)	k	Erro	TFN	TFP	TVP	TVN	$D_{KL}(g)$
10	1,5	7,94%	10,42%	7,15%	92,85%	89,58%	0,132
20	2,5	7,53%	7,93%	7,41%	92,59%	92,07%	0,074
30	2,5	<b>7,23%</b>	9,78%	6,40%	93,60%	90,22%	<b>0,022</b>
50	3	<b>7,14%</b>	9,30%	6,44%	93,56%	90,70%	<b>0,031</b>
100	3,5	7,57%	11,68%	6,16%	93,84%	88,32%	0,069
150	4	8,66%	15,03%	6,38%	93,62%	84,97%	0,212

As curvas obtidas pelo GMM são representadas como linhas sólidas na Figura 24a para cada par de parâmetros encontrados na análise de erro, enquanto as linhas tracejadas representam o modelo ajustado pelos dados da análise visual. A similaridade entre a distribuição do período obtido pela segmentação automática e a referência obtida pela inspeção visual foram medidas pela métrica KLD. Essa métrica foi calculada em função da janela de suavização como mostrado na Figura 24b.

A janela de suavização em  $W = 30$  ms com um fator de limiar de  $k = 2,5$  gera períodos com distribuição similar à referência visual, alcançando o menor KLD de 0,02 e um erro relativamente pequeno de 7,23%. Dessa forma, esse par de parâmetros foi escolhido para segmentar a série-temporal. Usar  $W = 50$  ms (e  $k=3,0$ ) também levaria à um erro e KLD semelhante. Para os parâmetros escolhidos, a taxa de falsos negativos

**Figura 25: Histograma e GMM do período mastigatório obtido a partir de inspeção visual (a) e pelo método de segmentação DTOS (b).**



**Fonte: Autoria própria**

(FNR) é relativamente alta em relação à taxa de falsos positivos (FPR), confirmando que a segmentação por limiar negligencia a primeira porção (cauda inicial) do sinal identificado por inspeção visual. Esse efeito se torna mais claro com janelas de suavização maiores, visto que a amplitude do sinal se torna cada vez mais reduzida. Por outro lado, janelas de suavização pequenas aumentam sensivelmente a taxa de falsos positivos pelo aumento da detecção errônea de sinais anômalos.

O histograma e o ajuste do GMM dos períodos inspecionados visualmente são mostrados na Figura 25a. Como sinais anômalos são rejeitados durante a inspeção, a curva ajustada aproxima uma única distribuição normal. Após determinar os melhores parâmetros, o GMM final do período do sinal de EMG relativo à movimentos mastigatórios obtido pelo método DTOS foi ajustado (Figura 25b).

A menor componente no GMM obtida pela segmentação DTOS pode estar associada com movimentos anômalos, como movimentos de cabeça, deglutição e movimentos de língua. Esses movimentos são de certa forma refletidos no sinal de EMG do músculo masseter, o qual é sinergista de outros músculos da cabeça. Além disso, o movimento de mastigação é composto de três fases: abertura mandibular, oclusão e lateralização. O sinal de interesse se situa entre as duas últimas fases, quando o animal performa o processamento do alimento com maior potência, sendo a força necessária proporcional à resistência mecânica do alimento. Portanto, a componente menor não é necessariamente um sinal de interesse, visto que está relacionada com a primeira fase do ciclo mastigatório (abertura mandibular). Uma menor janela de suavização, que pode ser vista como um filtro passa-baixa menos restritivo, leva a uma maior taxa de falsos

positivos visto que essa fase é detectada. Alternativamente, mitigar a detecção dessa fase leva a falsos negativos, já que alguns detalhes do sinal são filtrados, demandando maiores valores de limiar. Dessa forma partes de interesse do sinal que estejam abaixo do limiar serão negligenciadas. A segmentação deve considerar o compromisso entre esses dois efeitos, e portanto, dificilmente será possível ter uma precisão perfeita usando métodos não-supervisionados de extração de características.

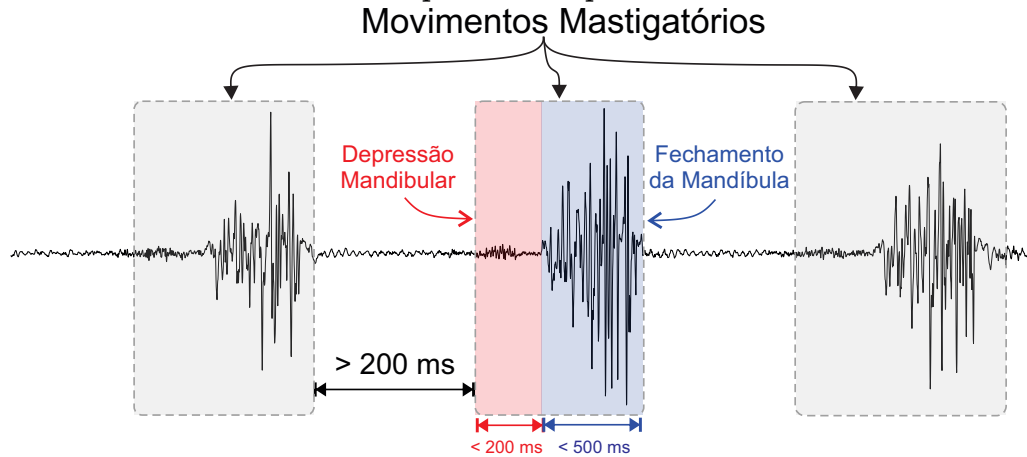
### 5.3 CLASSIFICAÇÃO

A Figura 26 mostra um fragmento de um sinal de série temporal de sEMG durante ingestão, onde os movimentos de abertura e oclusão/lateralização são destacados junto com a duração de cada fase. Nota-se o comportamento bifásico da mastigação composto por um sinal pequeno e curto (com duração de menos de 200 ms) seguido por um outro de maior amplitude e mais longo (que não dura mais do que 500 ms). O primeiro é o resultado do músculo masseter agindo como sinergista durante a ação de abertura da boca (depressão mandibular). O segundo está relacionado com a ação do masseter durante a oclusão e lateralização na fase de cominuição do *bolus* alimentar, quando as estruturas fibrosas são reduzidas à pequenas partículas por trituração e moagem que ao serem ensalivadas tornam-se aptas a serem deglutidas. Esse padrão também ocorre durante a ruminação, onde o *bolus* ruminal retorna e é reprocessado e deglutido novamente, porém já pré-cominuído e insalivado. Embora os processos sejam similares, existem particularidades quanto ao esforço requerido, amplitude da abertura mandibular e regularidade da mastigação. O período entre movimentos mastigatórios e o esforço aplicado é quase constante durante a ruminação, porém varia durante o bocado dependendo de diversos fatores, como por exemplo, a quantia de alimento disponível. Não obstante, em ambas atividades o intervalo entre eles é sempre superior a 200 ms.

A classificação foi inicialmente avaliada pela extração de características de segmentos do sinal definidos por janelas de tamanho variável e fixo. Os limites da janela variável são definidos pelo limiar de *onset* e *offset*, enquanto a janela fixa é definida apenas pelo *onset* com limites de 100 ms antes do sinal atingir o limiar ( $W_{bw}$ ) e 400 ms após ( $W_{fw}$ ), totalizando uma época de de 500 ms. Dessa forma, é garantido que todo o sinal é enquadrado e não se sobrepõe com sinais de mastigação próximos (anteriores ou posteriores).

O resultado usando características extraídas de forma não-supervisionada (*hand-crafted*) usando janelas de tamanho fixo e variável são mostrados na Figura 27. O resultado

**Figura 26: Fragmento de sinal de sEMG durante ingestão. O série-temporal bifásica é composta por um sinal de menor amplitude com duração de menos de 200 ms seguido por um sinal de maior amplitude com duração menor que 500 ms. O intervalo entre as duas fases é sempre maior que 200 ms.**

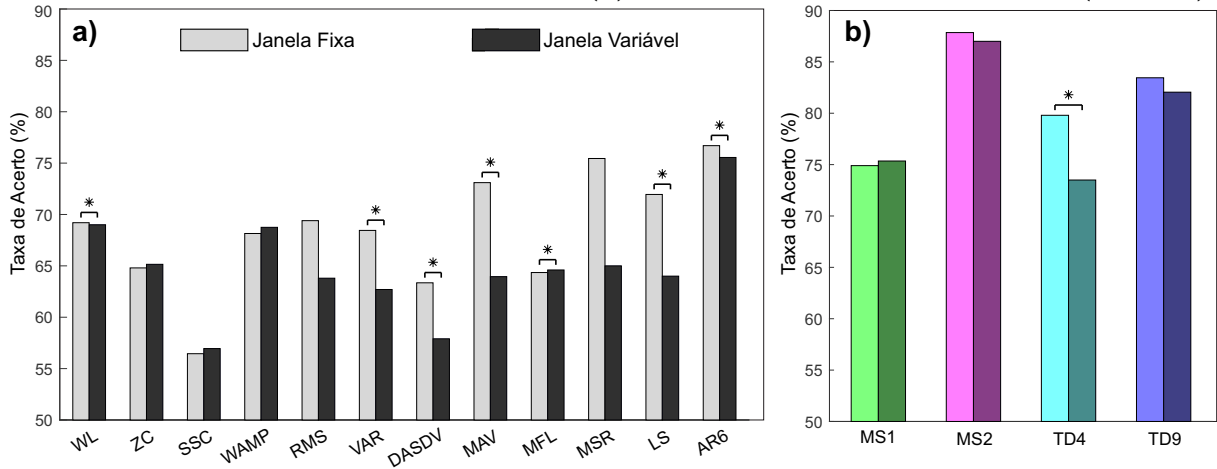


**Fonte: Autoria própria**

médio de classificação usando características individuais e em conjunto (*feature sets*) como entrada são exibidas em forma de gráfico de barras na Figura 27a e Figura 27b, respectivamente. Pares de barras sinalizadas com asterisco (\*) indicam uma diferença significativa ( $p < 0,05$ ). Analisando as características de forma individual, MAV, RMS, VARM, DASDV, MSR e LS obtiveram performance significativamente melhor quando extraídas de janela fixa. Com relação aos conjuntos, o método de janela de tamanho fixo atingiu melhores resultados de precisão de classificação para TD4 em relação ao método com janela variável. Não foram observadas características ou conjuntos que resultaram em performance de classificação significativamente melhor usando janela variável ao nível de significância de  $p < 0,05$ . O melhor desempenho individual foi atingido ao se utilizar os coeficientes do modelo Auto-Regressivo (AR6), chegando a uma precisão média de 75%, entretanto, essa característica é multi-dimensional. A característica unidimensional que levou a um melhor desempenho foi o Valor Médio da Raiz Quadrada (MSR). Com relação aos conjuntos de características, o MS2 teve melhor performance que os demais ( $p < 0,05$ ), alcançando uma performance de 87.85% com janela de tamanho fixo.

Diferentemente do método tradicional baseado em extração não-supervisionada de características, o método FDDL usa a reconstrução esparsa baseada em dicionário treinados para identificar a qual classe a instância pertence. Um exemplo do processo de reconhecimento de padrão de uma instância de EMG usando FDDL é ilustrado na Figura 28. Um exemplo de segmento de sinal (Figura 28a) é representado como um vetor esparsa para cada dicionário específico à classe (Figura 28b), o qual é usado para obter um

**Figura 27: Resultados de classificação para características individuais (a) e em conjuntos (b). Barra à esquerda representa características extraídas de janela fixa e à direita de janela variável. Asteriscos (\*) indicam diferença significativa ( $p < 0,05$ ).**



Fonte: Autoria própria

termo de erro (Figura 28c). Esse termo resultante de cada dicionário define a qual classe o exemplo pertence (Figura 28d). No exemplo proposto o termo de erro mínimo é observado para o dicionário de Consumo, então, o sinal é atribuído como sendo pertencente a essa classe.

O desempenho do reconhecimento de padrão mioelétrico usando FDDL é mostrado na Figura 29a, onde a precisão média e o desvio padrão (barras verticais) em função do tamanho do dicionário são apresentados. O classificador atingiu o melhor resultado usando um dicionário com 400 átomos (colunas), em que a taxa de acertos média foi de 89.9%. Os parâmetros foram ajustados para melhor performance, resultando nos seguintes valores:  $\lambda_1 = 0,01$ ,  $\lambda_2 = 0,01$ ,  $\eta = 1$ ,  $\gamma = 0,001$  e  $w = 0,1$ . A Figura 29b apresenta um diagrama de caixas (*boxplot*) dos melhores resultados usando o esquema tradicional baseado na extração de características e o método proposto (FDDL). As barras verticais<sup>1</sup> representam os valores extremos, os limites da caixa são os percentis 25 e 75 (primeiro e terceiro quartil) e linha central é a mediana (segundo quartil). Os asteriscos sinalizam diferença significativa ( $p < 0,05$ ) em relação ao método proposto (FDDL). Resultados sugerem que o método baseado em aprendizado de dicionário desempenha significativamente melhor em relação ao método tradicional usando quatro métodos estado-da-arte de extração de características.

<sup>1</sup>Muitas vezes essas barras verticais também são chamadas de bigodes, sendo o *boxplot* também chamado de diagrama de caixas e bigodes.

Figura 28: Procedimento de classificação de um sinal de EMG usando FDDL. Um segmento de sinal de EMG (a) é representado como um vetor de esparsos (b) o qual é usado para obter um termo de erro (c) que define a qual classe o exemplo pertence (d).

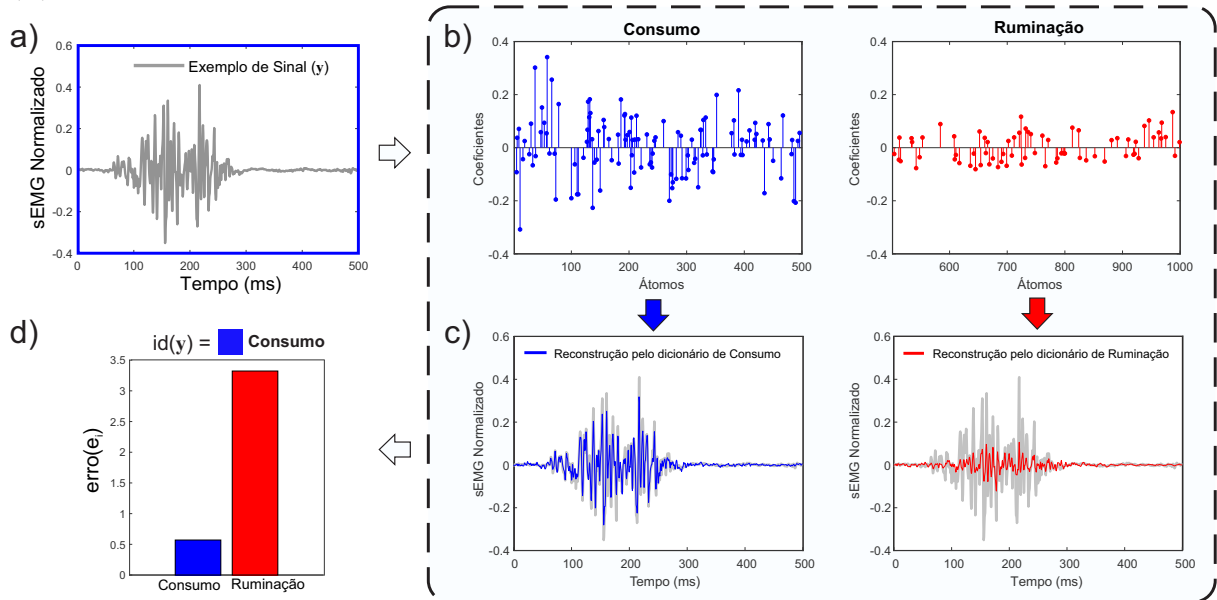
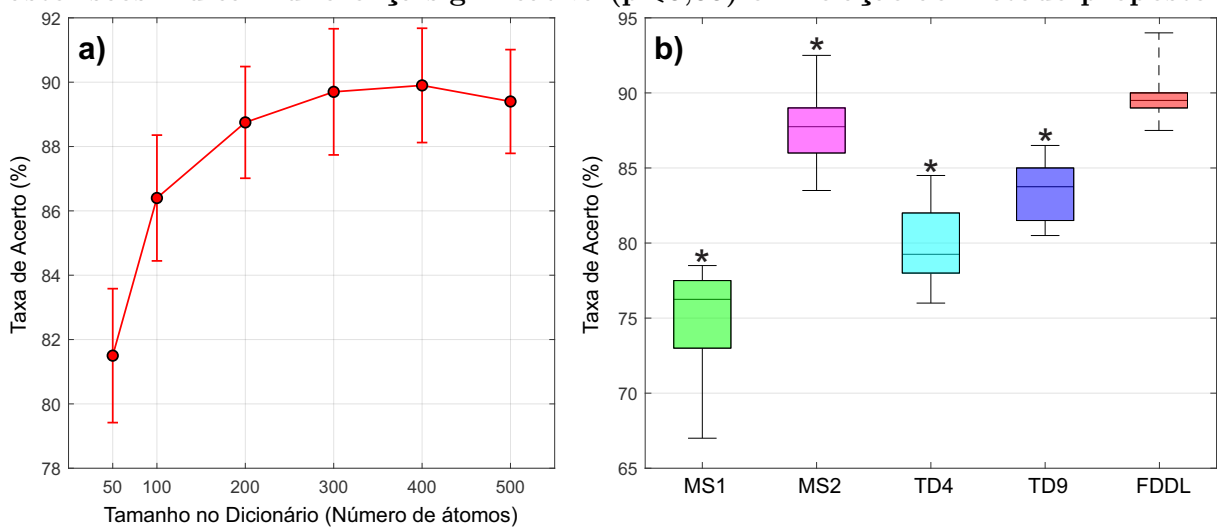



Figura 29: Resultados do reconhecimento de padrão eletromiográfico usando o método proposto. Taxa de acertos média e desvio padrão usando FDDL com diferentes tamanhos de dicionário (a). Diagrama de caixas dos melhores resultados obtidos por extração não-supervisionada de características e FDDL (b). Os asteriscos indicam diferença significativa ( $p < 0,05$ ) em relação ao método proposto.



Para visualizar a performance de predição para cada classe, os resultados do



**Figura 30:** Matriz de confusão da classificação obtido pelo método FDDL (a) e pelo conjunto de características MS2 combinado com o classificador LDA (b).



**Fonte:** Autoria pr pria

FDDL e do melhor conjunto de caracter sticas (MS2) combinado com LDA foram detalhados em formato de matriz de confus o, expresso na Figura 30a e Figura 30b, respectivamente. A matriz de confus o demonstra como as inst ncias alvo (r tulo verdadeiro) foram atribu das a cada classe de sa da. O n mero de inst ncias de cada classe   balanceado, onde 1000 exemplos de rumina o (Nr) e 1000 exemplos de consumo de silagem (Ne) foram examinados. A diagonal principal representa o n mero de exemplos corretamente classificados, os quais devem compor idealmente 50% dos exemplos (1000 inst ncias).

A maior limita o do m todo proposto reside no fato de que alguns exemplos de rumina o s o classificados como consumo de silagem (7.8% do n mero total de inst ncias). Uma poss vel explica o para essa falha   que em certo ponto da mastiga o, o alimento parcialmente processado possui propriedades mec nicas similares ao material que retornou do rumem, resultando em um sinal de EMG com aspecto semelhante. Por outro lado, a classifica o baseada em caracter sticas apresenta confus o majoritariamente nos exemplos de consumo (7.6% do n mero total de inst ncias), o qual deve ocorrer por motivo semelhante. Enquanto FDDL   baseado em dicion rios que podem aprender uma ampla variedade de movimentos mastigat rios, os vetores de caracter sticas s o um conjunto de m tricas que idealmente n o devem apresentar variabilidade. Um classificador como LDA   treinador baseado na premissa que caracter sticas pertencentes   mesma classe devem possuir padr es semelhantes, ou seja, sua localiza o no plano multi-dimensional de caracter sticas devem possuir menor vari ncia entre si e maior vari ncia entre classes. Entretanto, antagonicamente   rumina o que apresenta padr es mastigat rios quase

invariantes, o bocado apresenta uma ampla variedade de movimentos mastigatórios ao longo do processo. Portanto, a confusão observada na classificação baseada em características também pode ser explicada pela variância dos dados durante o consumo de silagem.


Atingir maior precisão no reconhecimento de padrões do bocado tem uma importância maior para futura exploração dos padrões ingestivos. Os erros de ruminação podem ser mitigados usando técnicas de pós-processamento como o voto majoritário, já que durante essa atividade o animal performa um ciclo praticamente invariante de mastigações. Já durante o bocado, diversos sub-eventos devem acontecer como movimentos de apreensão, mastigações, movimentos mistos e movimentos de língua. Mesmo as características do alimento devem variar, afetando aspectos da ingestão. Dessa forma, a correta identificação de eventos durante o bocado é o primeiro passo para classificação de sub-eventos e identificação de características do alimento.

O desempenho da classificação dos quatro conjuntos de características (MS1, MS2, TD4, e TD9) e do FDDL foram avaliados na presença de Ruído Branco Gaussiano (WGN, do inglês *White Gaussian Noise*) adicionado nas instâncias de treinamento e teste da base de dados de EMG. A Figura 31 mostra a taxa de acertos em função da Razão Sinal-Ruído (SNR, do inglês *Signal-to-Noise Ratio*) para cada método. O SNR foi variado de 0 a 20 dB em passos de 1 dB. O método proposto apresentou maior taxa de acertos média para todos os níveis de ruído, atingindo 80,9% para adição severa de ruído (0 dB)<sup>2</sup>, enquanto o método MS2 obteve 78,45%.

---

<sup>2</sup>Uma SNR de 0 dB representa o caso em que proporção de potência de ruído adicionado é igual à potência do próprio sinal

**Figura 31: Desempenho de classificação dos quatro conjuntos de características e FDDL com ruído adicionado aos dados de EMG no treino e no teste.**



**Fonte: Autoria própria**


Para a presente aplicação, o FDDL se demonstrou como o método mais robusto para classificação de sinais ruidosos, tendo um ganho de performance de 2.45% (SNR de 0 dB) em relação ao melhor conjunto de características. A robustez do algoritmo pode estar relacionada às propriedades intrínsecas da codificação esparsa usando dicionários, visto que na reconstrução esparsa do sinal os ruídos são mitigados<sup>3</sup>. Essa propriedade se deve a maneira como o dicionário é treinado. Em cada iteração os átomos são atualizados buscando uma melhor representação das instâncias pela composição linear de elementos comuns. Como o ruído é um sinal aleatório, dificilmente existirá concordância da parcela de ruído entre diferentes instâncias, dessa forma dificilmente o dicionário irá atribuir aos átomos um protótipo de sinal referente ao ruído.

Dessa forma pode-se imaginar que se o dicionário é treinado utilizando apenas dados limpos, a classificação de dados ruidoso usando FDDL terá um desempenho melhor, visto que os átomos do dicionário serão compostos por protótipos de sinal livre de ruídos. Assim, durante a etapa de reconstrução, o sinal resultante terá ruídos atenuados. Essa hipótese foi avaliada adicionando ruído apenas ao conjunto de teste, cujos resultados são

<sup>3</sup>É por esse motivo que muitas vezes as técnicas de representação esparsas são utilizadas na remoção de ruídos de imagens.

mostrados na Figura 32.

**Figura 32: Desempenho de classificação dos quatro conjuntos de características e FDDL com ruído adicionado aos dados de EMG no teste.**



Fonte: Autoria própria

Pode-se observar que nesse cenário o FDDL apresenta desempenho praticamente inalterado pela presença de ruído. Do ponto de vista prático esse é a situação mais provável, em que o treinamento do classificador é feito com sinais coletados em condições controladas e o processamento em tempo-real pode apresentar qualquer natureza de ruído. Os demais métodos são prejudicados nesse caso, apresentando uma classificação praticamente aleatória para ruídos severos, próximos a 0 dB, onde o método proposto obteve 86,35% de taxa de acertos e o melhor conjunto de características (MS1) 71,6%, resultando em uma diferença de 14,75%. No caso mais extremo, com ruído de 5 dB, a diferença entre FDDL e o melhor conjunto nessa situação (TD9) é de 34,8%! Por fim, o melhor conjunto de características nesse cenário é o TD9, apresentando resultados superiores aos demais para ruídos acima de 3 dB, porém sempre abaixo dos resultados do método proposto (FDDL).

A disparidade se deve ao fato de que o classificador LDA é treinado para definir um hiperplano que separa os dados limpos, e dessa forma as características ruidosas não irão

necessariamente apresentar o mesmo comportamento. Pode-se imaginar, por exemplo, que características baseadas em contagem (e.g. SSC, ZC), terão sua distribuição estatística deslocada. Esse deslocamento pode fazer com que os dados estejam inteiramente de um só lado do hiperplano, como observado no conjunto MS2 que se mantém próximo a 50% para todos os níveis de ruído<sup>4</sup> pois todos os dados estão sendo classificados como uma única classe.

É interessante observar que o conjunto MS1 apresentou um resultado não monotônico em relação ao ruído, ou seja, o conjunto de Hudgins possui alguma característica com comportamento não-linear em relação ao ruído de forma que os resultados com ruídos ao nível de 0 dB são melhores do que em 5 dB. Esse fenômeno acontece quando a distribuição da característica não apenas se desloca, mas também tem sua variância aumentada proporcionalmente ao ruído, o que propicia que a cauda estendida da distribuição cruze o hiperplano de separação, resultando em uma taxa de acertos maior do que a probabilidade do evento ocorrer ao acaso<sup>5</sup>.

---

<sup>4</sup> Isso se deve provavelmente a sensibilidade da característica AR6 ao ruído (PHINYOMARK et al., 2009).

<sup>5</sup> Uma explicação estendida pode ser encontrada no Apêndice D.

## 6 CONCLUSÃO

Esse trabalho apresentou um método para investigar os padrões mastigatórios de ruminação e ingestão em bovinos a partir de um método de classificação do sinal de sEMG do músculo masseter baseado em representações esparsas de sinais de aprendizado de dicionário (FDDL)<sup>1</sup>. O método foi confrontando com quatro técnicas estado-da-arte baseadas na extração não-supervisionada de características combinadas com uma técnica de aprendizado de máquina (LDA). Resultados indicaram que o método FDDL apresenta desempenho de classificação significativamente melhor e mais robusto na presença de ruídos em relação aos métodos reproduzidos da literatura. Ademais, um protocolo de segmentação foi apresentado com o objetivo de selecionar janelas correspondentes aos sinais gerados por atividades mastigatórias, negligenciando sinais anômalos.

A vantagem da técnica escolhida (EMG) é que, diferentemente das inúmeras técnicas de monitoramento encontradas na literatura, os eventos ingestivos podem ser identificados a partir de um único movimento mastigatório. Ainda, a técnica proposta tem o potencial de ser expandida para reconhecimento de características do alimento sendo ingerido e identificação de sub-eventos mastigatórios, o que não poderia acontecer por exemplo em técnicas baseadas em acelerômetros, bioacústica ou sensores de pressão. Por exemplo, mesmo as estatísticas dos movimentos mastigatórios, como duração e intervalo, são dados obtidos apenas pelos sensores de pressão. Ainda, o reconhecimento do tipo de alimento e estimação de consumo são informações até então só obtidas pela eletromiografia de superfície. Dessa forma, além da técnica utilizada já obter uma série de informações exclusivas, ainda existe uma maior potencialidade em relação aos demais métodos com relação à expansão do número de padrões a serem classificados, dependendo apenas do aperfeiçoamento dos métodos de processamento. Portanto, o método proposto corrobora com a melhoria de uma técnica com potencial ainda pouco explorado.

O método proposto é uma alternativa ao esquema de processamento convencional

---

<sup>1</sup>Os algoritmos utilizados nesse trabalho serão disponibilizados pelo link após a divulgação dos resultados em periódico : <https://github.com/camposdp/ruminant-emg>.

de sinais de sEMG (extração de características, redução de dimensionalidade e classificação), prescindindo a busca por uma combinação ótima de características do sinal e técnica de separação de dados. Como o método FDDL é baseado no treinamento de dicionário para cada classe, ele se apresenta robusto aos desvios entre amostras, como instâncias fora do *locus* no espaço multi-dimensional das características<sup>2</sup> ou dados heterogeneamente ruidosos. Ademais, o dicionário treinado pode ser usado para compressão e reconstrução de dados, facilitando o envio remoto de dados em aplicações embarcadas<sup>3</sup>. Uma possível desvantagem é o custo computacional, não avaliado nesse trabalho, que pode ser maior do que os métodos presentes na literatura. Dessa forma, o método é apropriado para processamentos *offline*, necessitando análise e otimização computacional para permitir processamento em tempo-real. Além disso, um problema geral dos métodos supervisionados é a necessidade de rotular os dados, os quais demandam trabalho do operador.

Trabalhos futuros devem avaliar o método com mais de duas classes, incluindo o tipo e altura de pasto sendo ingerido pelo animal. Adicionalmente, esse e outros métodos baseados em aprendizado de dicionário deverão ser avaliados como uma alternativa para os métodos presentes e amplamente difundidos e utilizados baseados em extração não-supervisionada de características na classificação de padrões eletromiográficos em humanos<sup>4</sup>. Finalmente, analisar-se-á detalhadamente o custo computacional e comparada com as abordagens estado-da-arte. Caso viável, a técnica será embarcada em um sistema eletrônico de monitoramento vestível para monitoramento em tempo-real de animais ruminantes.

---

<sup>2</sup>Esse espaço multi-dimensional se refere à uma analogia com os dados não separáveis quando projetados em um espaço de características.

<sup>3</sup>Como o sinal esparsa pode reconstruir o sinal por codificação esparsa, transmitir os coeficientes é muito menor que o sinal bruto. A compactação e o custo de codificação irão depender do tamanho do dicionário e da densidade do vetor de coeficientes porém com o compromisso do erro de reconstrução.

<sup>4</sup>Aqui referindo-se ao contexto de reconhecimento de padrões eletromiográficos para controle de próteses robóticas em amputados e indivíduos com limitação motora. Esse problema tem sido exaustivamente estudado por diversos grupos de pesquisa e como ainda os métodos são incipientes e quase sempre baseados no trabalho de Sísifo de criar e combinar características, classificadores e técnicas de pré e pós-processamento. Portanto, o método aqui apresentado pode fornecer uma alternativa viável e fora do *mainstream* para essa finalidade

## REFERÊNCIAS

- ABIEC. **Beef Report**. 2019. Website. Disponível em: <<http://www.abiec.com.br/Sumario2019.aspx>>.
- Ahmadvand, P.; Ebrahimpour, R.; Ahmadvand, P. How popular cnns perform in real applications of face recognition. In: **2016 24th Telecommunications Forum (TELFOR)**. [S.l.: s.n.], 2016. p. 1–4.
- AMARAL, M. F. et al. Sward structure management for a maximum short-term intake rate in annual ryegrass. **Grass and Forage Science**, v. 68, n. 2, p. 271–277, 2013. ISSN 1365-2494. Disponível em: <<http://dx.doi.org/10.1111/j.1365-2494.2012.00898.x>>.
- ANDRIAMANDROSO, A. L. H. et al. A review on the use of sensors to monitor cattle jaw movements and behavior when grazing. **Biotechnologie, Agronomie, Société et Environnement**, v. 20, p. 273–286, 2016. ISSN 1780-4507. Disponível em: <<http://hdl.handle.net/2268/197763>>.
- ANDRIAMANDROSO A. L. H., J. B. B. M.; LEBEAU., F. A review on the use of sensors to monitor cattle jaw movements and behavior when grazing A review on the use of sensors to monitor cattle jaw movements and behavior when grazing. **Biotechnology, Agronomy, Society and Environment**, v. 20, n. Supp. 1, p. 273–286, 2016. ISSN 1370-6233.
- BAIOCO, G. L. et al. Avaliação da eletromiografia na contagem de movimentos mastigatórios e na estimação de consumo. In: SBEB. **Congresso Brasileiro de Eletromiografia e Cinesiologia (COBEC)**. Uberlândia, 2017.
- BALOUCHESTANI, M.; KRISHNAN, S. Robust compressive sensing algorithm for wireless surface electromyography applications. **Biomedical Signal Processing and Control**, Elsevier Ltd, v. 20, p. 100–106, 2015.
- BARWICK, J. et al. Predicting lameness in sheep activity using tri-axial acceleration signals. **Animals**, v. 8, n. 1, 2018. ISSN 2076-2615. Disponível em: <<http://www.mdpi.com/2076-2615/8/1/12>>.
- BEAUCHEMIN, K. et al. An automatic system for quantification of eating and ruminating activities of dairy cattle housed in stalls. **Journal of Dairy Science**, v. 72, n. 10, p. 2746 – 2759, 1989. ISSN 0022-0302. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022030289794182>>.
- BENAISSA, S. et al. Classification of ingestive-related cow behaviours using rumiwatch halter and neck-mounted accelerometers. **Applied Animal Behaviour Science**, v. 211, p. 9 – 16, 2019. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S016815911830409X>>.



Betthausen, J. L. et al. Limb position tolerant pattern recognition for myoelectric prosthesis control with adaptive sparse representations from extreme learning. **IEEE Transactions on Biomedical Engineering**, v. 65, n. 4, p. 770–778, April 2018. ISSN 0018-9294.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. [S.l.]: Springer, 2006. ISSN 1613-9011.

BITSZ ENGINEERING. **Myo-Sensor MS15**. 2014. Website. Products. Disponível em: <<http://www.bitsz-engineering.de/downloads/DatenblattMyoSensorMS15.pdf>>.

BOEVER, J. D. et al. Evaluation of physical structure. 1. grass silage. **Journal of Dairy Science**, v. 76, n. 1, p. 140 – 153, 1993. ISSN 0022-0302. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022030293773336>>.

BREMM, C. et al. Foraging behaviour of beef heifers and ewes in natural grasslands with distinct proportions of tussocks. **Applied Animal Behaviour Science**, v. 141, n. 3–4, p. 108 – 116, 2012. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168159112002481>>.

BÜCHEL, S.; SUNDRUM, A. Technical note: Evaluation of a new system for measuring feeding behavior of dairy cows. **Computers and Electronics in Agriculture**, v. 108, n. 0, p. 12 – 16, 2014. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169914001707>>.

CAMPOS, D. P. et al. Segmentação, extração de atributos e análise da eletromiografia do músculo masseter para caracterização da mastigação. In: SBEB. **XXV Congresso Brasileiro de Engenharia Biomédica (CBEB)**. Florianópolis, 2016. p. 1841–1844.

CAMPOS, D. P. et al. Surface electromyography measurements for ingestive behaviour identification on goats. In: IEEE. **VII Latin American Symposium on Circuits and Systems (LASCAS)**. Florianópolis, 2016. p. 271–274.

CAMPOS, D. P. et al. Surface electromyography segmentation and feature extraction for ingestive behavior recognition in ruminants. **Computers and Electronics in Agriculture**, v. 153, p. 325 – 333, 2018. ISSN 0168-1699.

CAMPOS, D. P. et al. Ingestive pattern recognition on cattle using emg segmentation and feature extraction. In: COSTA-FELIX, R.; MACHADO, J. C.; ALVARENGA, A. V. (Ed.). **XXVI Brazilian Congress on Biomedical Engineering**. Singapore: Springer Singapore, 2019. p. 281–288. ISBN 978-981-13-2517-5.

CAMPOS, D. P. et al. Short-term fibre intake estimation in goats using surface electromyography of the masseter muscle. **Biosystems Engineering**, v. 183, p. 209 – 220, 2019. ISSN 1537-5110. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1537511017308164>>.

CHOWDHURY, R. H. et al. Surface electromyography signal processing and classification techniques. **Sensors**, v. 13, n. 9, p. 12431–12466, 2013. ISSN 1424-8220. Disponível em: <<http://www.mdpi.com/1424-8220/13/9/12431>>.

- CLAPHAM, W. M. et al. Acoustic monitoring system to quantify ingestive behavior of free-grazing cattle. **Computers and Electronics in Agriculture**, v. 76, n. 1, p. 96 – 104, 2011. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S016816991100024X>>.
- CLARK, J. J. W. et al. **Medical Instrumentation: Application and Design**. 2. ed. [S.l.]: Houghton Mifflin Company, 1992.
- CRAM, J.; CRISWELL, E. **Cram's Introduction to Surface Electromyography**. Jones & Bartlett Learning, 2011. ISBN 9780763732745. Disponível em: <<https://books.google.com.br/books?id=RgfX5jXrmzMC>>.
- CUYER, ; HAYWOOD, G. **Artistic anatomy of animals** /. London :Baillière, Tindall Cox., 1905. 348 p. <https://www.biodiversitylibrary.org/bibliography/30296> — Translation of Anatomie artistique des animaux. Disponível em: <<https://www.biodiversitylibrary.org/item/73937>>.
- DAUBE, J. **Clinical Neurophysiology**. Oxford University Press, USA, 2002. (Contemporary Neurology Series). ISBN 9780195140804. Disponível em: <<https://books.google.com.br/books?id=K5QiZzacCjgC>>.
- DELAGARDE, R.; LAMBERTON, P. Daily grazing time of dairy cows is recorded accurately using the lifecorder plus device. **Applied Animal Behaviour Science**, v. 165, p. 25 – 32, 2015. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168159115000325>>.
- DESWYSEN, A.; ELLIS, W. Fragmentation and ruminal escape of particles as related to variations in voluntary intake, chewing behavior and extent of digestion of potentially digestible ndf in heifers. **Journal of Animal Science**, v. 68, n. 11, p. 3871–9, 1990. Disponível em: <<http://www.journalofanimalscience.org/content/68/11/3871.abstract>>.
- DING, Z. et al. sEMG-based gesture recognition with convolution neural networks. **Sustainability (Switzerland)**, v. 10, n. 6, p. 1–12, 2018. ISSN 20711050.
- DISTEL, R. et al. Patch selection by cattle: maximization of intake rate in horizontally heterogeneous pastures. **Applied Animal Behaviour Science**, v. 45, n. 1–2, p. 11 – 21, 1995. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/016815919500593H>>.
- ELAD, M. **Sparse and Redundant Representations: From Theory to Applications in Signal and Image Processing**. [S.l.]: Springer New York, 2010. ISBN 9781441970114.
- FENG, Z. et al. Joint discriminative dimensionality reduction and dictionary learning for face recognition. **Pattern Recognition**, Elsevier, v. 46, n. 8, p. 2134–2143, 2013. ISSN 0031-3203. Disponível em: <<http://dx.doi.org/10.1016/j.patcog.2013.01.016>>.
- FOGARTY, E. S. et al. Autonomous on-animal sensors in sheep research : A systematic review. **Computers and Electronics in Agriculture**, Elsevier, v. 150, n. April, p. 245–256, 2018. ISSN 0168-1699. Disponível em: <<https://doi.org/10.1016/j.compag.2018.04.017>>.

FUEKI, K. et al. Association between food mixing ability and electromyographic activity of jaw-closing muscles during chewing of a wax cube. **Journal of Oral Rehabilitation**, Blackwell Publishing Ltd, v. 35, n. 5, p. 345–352, 2008. ISSN 1365-2842. Disponível em: <<http://dx.doi.org/10.1111/j.1365-2842.2008.01849.x>>.

GALLI, J. et al. Acoustic monitoring of chewing and intake of fresh and dry forages in steers. **Animal Feed Science and Technology**, v. 128, n. 1–2, p. 14 – 30, 2006. ISSN 0377-8401. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0377840105003688>>.

GALLI, J. et al. Acoustic monitoring of short-term ingestive behavior and intake in grazing sheep. **Livestock Science**, v. 140, n. 1–3, p. 32 – 41, 2011. ISSN 1871-1413. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1871141311000473>>.

GENG, Y. et al. A Robust Sparse Representation Based Pattern Recognition Approach for Myoelectric Control. **IEEE Access**, IEEE, v. 6, n. July, p. 38326–38335, 2018.

GINANE, C.; PETIT, M.; D'HOOR, P. How do grazing heifers choose between maturing reproductive and tall or short vegetative swards? **Applied Animal Behaviour Science**, v. 83, n. 1, p. 15 – 27, 2003. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168159103001102>>.

GIOVANETTI, V. et al. Automatic classification system for grazing, ruminating and resting behaviour of dairy sheep using a tri-axial accelerometer. **Livestock Science**, Elsevier, v. 196, n. September 2016, p. 42–48, 2017. ISSN 18711413. Disponível em: <<http://dx.doi.org/10.1016/j.livsci.2016.12.011>>.

GOMES, O. A. et al. Sistema de aquisição de sinais de semg para o estudo do comportamento ingestivo em ruminantes. In: SBEB. **Congresso Brasileiro de Eletromiografia e Cinesiologia (COBEC)**. Uberlândia, 2017.

GONZÁLEZ, L. A.; KYRIAZAKIS, I.; TEDESCHI, L. O. Review: Precision nutrition of ruminants: approaches, challenges and potential gains. **animal**, Cambridge University Press, v. 12, n. s2, p. s246–s261, 2018.

GUO, L. et al. Comparison of grazing behaviour of sheep on pasture with different sward surface heights using an inertial measurement unit sensor. **Computers and Electronics in Agriculture**, v. 150, p. 394 – 401, 2018. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169917311936>>.

HALACHMI, I. et al. Smart animal agriculture: Application of real-time sensors to improve animal well-being and production. **Annual Review of Animal Biosciences**, v. 7, n. 1, p. 403–425, 2019. PMID: 30485756.

HAZARIKA, A. et al. F-svd based algorithm for variability and stability measurement of bio-signals, feature extraction and fusion for pattern recognition. **Biomedical Signal Processing and Control**, v. 47, p. 26 – 40, 2019. ISSN 1746-8094. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1746809418302003>>.

HERMENS, H. J. et al. Development of recommendations for {SEMG} sensors and sensor placement procedures. **Journal of Electromyography and**

**Kinesiology**, v. 10, n. 5, p. 361 – 374, 2000. ISSN 1050-6411. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1050641100000274>>.

HILL, K. O.; MELTZ, G. Fiber bragg grating technology fundamentals and overview. **Lightwave Technology, Journal of**, v. 15, n. 8, p. 1263–1276, Aug 1997. ISSN 0733-8724.

HODGES, P. W.; BUI, B. H. A comparison of computer-based methods for the determination of onset of muscle contraction using electromyography. **Electroencephalography and Clinical Neurophysiology/Electromyography and Motor Control**, v. 101, n. 6, p. 511 – 519, 1996. ISSN 0924-980X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0921884X96951905>>.

HOSKING, J. R. M. L-moments: Analysis and estimation of distributions using linear combinations of order statistics. **Journal of the Royal Statistical Society. Series B (Methodological)**, [Royal Statistical Society, Wiley], v. 52, n. 1, p. 105–124, 1990. ISSN 00359246. Disponível em: <<http://www.jstor.org/stable/2345653>>.

HU, Y. et al. A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition. **Plos One**, v. 13, n. 10, p. e0206049, 2018. ISSN 1932-6203. Disponível em: <<http://dx.plos.org/10.1371/journal.pone.0206049>>.

HUDGINS, B.; PARKER, P.; SCOTT, R. A new strategy for multifunction myoelectric control. **Biomedical Engineering, IEEE Transactions on**, v. 40, n. 1, p. 82–94, Jan 1993. ISSN 0018-9294.

IBGE. **Censo Agropecuário**. 2017. Website. Disponível em: <<https://censos.ibge.gov.br/agro/2017/>>.

IQBAL, N. V.; SUBRAMANIAM, K.; Shaniba Asmi, P. A Review on Upper-Limb Myoelectric Prosthetic Control. **IETE Journal of Research**, Taylor & Francis, v. 64, n. 6, p. 740–752, 2018. ISSN 0974780X. Disponível em: <<https://doi.org/10.1080/03772063.2017.1381047>>.

JIANG, Z.; LIN, Z.; DAVIS, L. S. Label consistent k-svd: Learning a discriminative dictionary for recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 35, n. 11, p. 2651–2664, Nov 2013. ISSN 0162-8828.

JUNIOR, J. J. A. M. et al. Avaliação de técnicas de segmentação de semg de múltiplos canais. In: SBEB. **Congresso Brasileiro de Eletromiografia e Cinesiologia (COBEC)**. Uberlândia, 2017.

KAMEN, G.; GABRIEL, D. **Essentials of Electromyography**. Human Kinetics, 2010. ISBN 9781450408530. Disponível em: <<https://books.google.com.br/books?id=9izzXnnKzJoC>>.

KARAM, L. Z. et al. In vivo analysis of bone strain using fiber bragg grating sensor and decision tree algorithm in bovine during masticatory movements. In: **Microwave and Optoelectronics Conference (IMOC), 2015 SBMO/IEEE MTT-S International**. [S.l.: s.n.], 2015. p. 1–4.

KEMSLEY, E. et al. Electromyographic responses to prescribed mastication. **Journal of Electromyography and Kinesiology**, v. 13, n. 2, p. 197 – 207, 2003. ISSN 1050-6411. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1050641102000652>>.

KEMSLEY, E. et al. Multivariate analysis of electromyographic (emg) frequency spectra to characterise mastication. **Journal of Texture Studies**, Blackwell Publishing Ltd, v. 33, n. 1, p. 15–34, 2002. ISSN 1745-4603. Disponível em: <<http://dx.doi.org/10.1111/j.1745-4603.2002.tb01332.x>>.

KHUSHABA, R. N. et al. Combined influence of forearm orientation and muscular contraction on EMG pattern recognition. **Expert Systems with Applications**, Elsevier Ltd, v. 61, p. 154–161, 2016. ISSN 09574174. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2016.05.031>>.

KONONOFF, P.; LEHMAN, H.; HEINRICHS, A. Technical note—a comparison of methods used to measure eating and ruminating activity in confined dairy cattle. **Journal of Dairy Science**, v. 85, n. 7, p. 1801 – 1803, 2002. ISSN 0022-0302. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022030202742549>>.

KONRAD, P. **The ABC of EMG: A Practical Introduction to Kinesiological Electromyography**. 2006. ISBN 0-9771622-1-4. Disponível em: <[http://www.noraxon.com/sdm\\_downloads/abc-of-emg/](http://www.noraxon.com/sdm_downloads/abc-of-emg/)>.

KRISHNAN, S.; ATHAVALE, Y. Trends in biomedical signal feature extraction. **Biomedical Signal Processing and Control**, v. 43, p. 41 – 63, 2018. ISSN 1746-8094.

LACA; WALLISDEVRIES. Acoustic measurement of intake and grazing behaviour of cattle. **Grass and Forage Science**, Blackwell Science Ltd, v. 55, n. 2, p. 97–104, 2000. ISSN 1365-2494. Disponível em: <<http://dx.doi.org/10.1046/j.1365-2494.2000.00203.x>>.

LACA, E.; UNGAR, E.; DEMMENT, M. Mechanisms of handling time and intake rate of a large mammalian grazer. **Applied Animal Behaviour Science**, v. 39, n. 1, p. 3 – 19, 1994. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0168159194900116>>.

LAW, S. E.; SUDWEEKS, E. M. Electronic transducer for rumination research. **Journal of Animal Science**, v. 41, n. 1, p. 213–218, 1975. Disponível em: <<http://www.journalofanimalscience.org/content/41/1/213.abstract>>.

LEIBER, F. et al. Intake estimation in dairy cows fed roughage-based diets: An approach based on chewing behaviour measurements. **Applied Animal Behaviour Science**, v. 185, p. 9 – 14, 2016. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168159116302908>>.

LUCA, C. D. The use of surface electromyography in biomechanics. **Journal of Applied Biomechanics**, v. 13, p. 135–163, 1997.

LUGINBUHL, J. et al. A simple electronic device and computer interface system for monitoring chewing behavior of stall-fed ruminant animals. **Journal of Dairy Science**, v. 70, n. 6, p. 1307 – 1312, 1987. ISSN 0022-0302. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022030287801467>>.

MAMBRITO, B.; LUCA, C. J. D. A technique for the detection, decomposition and analysis of the {EMG} signal. **Electroencephalography and Clinical Neurophysiology**, v. 58, n. 2, p. 175 – 188, 1984. ISSN 0013-4694. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0013469484900312>>.

MANSBRIDGE, N. et al. Feature selection and comparison of machine learning algorithms in classification of grazing and rumination behaviour in sheep. **Sensors**, v. 18, n. 10, 2018. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/18/10/3532>>.

MATSUI, K. A new ambulatory data logger for a long-term determination of grazing and rumination behaviour on free-ranging cattle, sheep and goats. **Applied Animal Behaviour Science**, v. 39, n. 2, p. 123 – 130, 1994. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0168159194901325>>.

MATSUI, K.; OKUBO, T. A method for quantification of jaw movements suitable for use on free-ranging cattle. **Applied Animal Behaviour Science**, v. 32, n. 2–3, p. 107 – 116, 1991. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168159105800358>>.

MERLETTI, R.; PARKER, P. **Electromyography:: Physiology, Engineering and Noninvasive Applications**. [S.l.]: John Wiley & Sons, Inc., 2004.

MILONE, D. et al. Automatic recognition of ingestive sounds of cattle based on hidden markov models. **Computers and Electronics in Agriculture**, v. 87, p. 51 – 55, 2012. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169912001184>>.

MILONE, D. et al. Computational method for segmentation and classification of ingestive sounds in sheep. **Computers and Electronics in Agriculture**, v. 65, n. 2, p. 228 – 237, 2009. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169908002214>>.

MOSER, A. C. et al. Desenvolvimento e avaliação de eletrodos metálicos passivos para eletromiografia de superfície. In: SBEB. **Congresso Brasileiro de Eletromiografia e Cinesiologia (COBEC)**. Uberlândia, 2017.

NADIN, L. B. et al. Comparison of methods to quantify the number of bites in calves grazing winter oats with different sward heights. **Applied Animal Behaviour Science**, v. 139, n. 1–2, p. 50 – 57, 2012. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S016815911200072X>>.

NATIONAL INSTRUMENTS. **Field Wiring and Noise Considerations for Analog Signals**. 2014. Website. Disponível em: <<http://www.ni.com/white-paper/3344/en/>>.

NORTON, T.; BERCKMANS, D. Engineering advances in Precision Livestock Farming. v. 3, p. 2018–2020, 2018.

OCTAVIANO, C. **Muito além da tecnologia: os impactos da Revolução Verde**. Campinas, 2010.

ORMOND, J. G. P. **Glossário de Termos Usados em Atividades Agropecuárias, Florestais e Ciências Ambientais**. Rio de Janeiro, 2006.

OSKOEI, M. A.; HU, H. Myoelectric control systems—a survey. **Biomedical Signal Processing and Control**, v. 2, n. 4, p. 275 – 294, 2007. ISSN 1746-8094. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1746809407000547>>.

OUDSHOORN, F. et al. Estimation of grass intake on pasture for dairy cows using tightly and loosely mounted di- and tri-axial accelerometers combined with bite count. **Computers and Electronics in Agriculture**, v. 99, p. 227 – 235, 2013. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169913002408>>.

PEGORINI, V. **Classificação De Padrões De Mastigação De Ruminantes Utilizando Aprendizagem De Máquina**. Dissertação (Dissertação de Mestrado) — Universidade Tecnológica Federal do Paraná - Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), Pato Branco, 2015. Orientador: Dr. Rafael Cardoso, Co-orientador: Dr. Richardson Ribeiro.

PEGORINI, V. et al. Design of electromyography classification system using artificial neural network. In: **XII Simpósio Brasileiro de Automação Inteligente (SBAI)**. [S.l.: s.n.], 2015. p. 1548–1552.

PEGORINI, V. et al. **In-vivo determination of chewing patterns using FBG and artificial neural networks**. 2015. 963427-963427-4 p. Disponível em: <<http://dx.doi.org/10.1117/12.2195642>>.

PEGORINI, V. et al. In vivo pattern classification of ingestive behavior in ruminants using fbg sensors and machine learning. **Sensors**, v. 15, n. 11, p. 28456, 2015. ISSN 1424-8220. Disponível em: <<http://www.mdpi.com/1424-8220/15/11/28456>>.

PENNING, P. D. A technique to record automatically some aspects of grazing and ruminating behaviour in sheep. **Grass and Forage Science**, Blackwell Publishing Ltd, v. 38, n. 2, p. 89–96, 1983. ISSN 1365-2494. Disponível em: <<http://dx.doi.org/10.1111/j.1365-2494.1983.tb01626.x>>.

PHINYOMARK, A.; KHUSHABA, R. N.; SCHEME, E. Feature extraction and selection for myoelectric control based on wearable emg sensors. **Sensors (Basel)**, MDPI, v. 18, n. 5, p. 1615, May 2018. ISSN 1424-8220.

PHINYOMARK, A.; LIMSAKUL, C.; PHUKPATTARANONT, P. A novel feature extraction for robust emg pattern recognition. **Journal of Computing**, v. 1, n. 1, p. 71–80, 2009.

PHINYOMARK, A.; PHUKPATTARANONT, P.; LIMSAKUL, C. Feature reduction and selection for emg signal classification. **Expert Systems with Applications**, v. 39, n. 8, p. 7420 – 7431, 2012. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417412001200>>.

PHINYOMARK, A. et al. Emg feature evaluation for improving myoelectric pattern recognition robustness. **Expert Systems with Applications**, v. 40, n. 12, p. 4832 – 4840, 2013. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417413001395>>.

PHINYOMARK, A. et al. Feature extraction of the first difference of EMG time series for EMG pattern recognition. **Computer Methods and Programs in Biomedicine**, Elsevier Ireland Ltd, v. 117, n. 2, p. 247–256, 2014. ISSN 18727565. Disponível em: <<http://dx.doi.org/10.1016/j.cmpb.2014.06.013>>.

RENTERO, N. **ANUÁRIO leite 2018**: Indicadores, tendências e oportunidades para quem vive no setor leiteiro. [S.l.: s.n.], 2018.

ROMBACH, M. et al. Evaluation and validation of an automatic jaw movement recorder (rumiwatch) for ingestive and rumination behaviors of dairy cows during grazing and supplementation. **Journal of Dairy Science**, v. 101, n. 3, p. 2463 – 2475, 2018. ISSN 0022-0302. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022030217311967>>.

ROOK, A.; HUCKLE, C.; PENNING, P. Effects of sward height and concentrate supplementation on the ingestive behaviour of spring-calving dairy cows grazing grass-clover swards. **Applied Animal Behaviour Science**, v. 40, n. 2, p. 101 – 112, 1994. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0168159194900752>>.

RUS, M. A. et al. Dairycheck - a sensor system for monitoring and analysis of the chewing activity of dairy cows. **Landtechnik**, v. 68, n. 6, p. 395–399, 2013. ISSN 00238082.

RUTTER, S. Graze: A program to analyze recordings of the jaw movements of ruminants. **Behavior Research Methods, Instruments, Computers**, Springer-Verlag, v. 32, n. 1, p. 86–92, 2000. ISSN 0743-3808. Disponível em: <<http://dx.doi.org/10.3758/BF03200791>>.

RUTTER, S.; CHAMPION, R.; PENNING, P. An automatic system to record foraging behaviour in free-ranging ruminants. **Applied Animal Behaviour Science**, v. 54, n. 2–3, p. 185 – 195, 1997. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168159196011914>>.

SAMUEL, O. W. et al. Pattern recognition of electromyography signals based on novel time domain features for amputees' limb motion classification. **Computers Electrical Engineering**, v. 67, p. 646 – 655, 2018. ISSN 0045-7906.

SAZONOV, E.; FONTANA, J. A sensor system for automatic detection of food intake through non-invasive monitoring of chewing. **Sensors Journal, IEEE**, v. 12, n. 5, p. 1340–1348, May 2012. ISSN 1530-437X.

SCHEIBE, K. et al. {ETHOSYS} (r)—new system for recording and analysis of behaviour of free-ranging domestic animals and wildlife. **Applied Animal Behaviour Science**, v. 55, n. 3–4, p. 195 – 211, 1998. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168159197000725>>.

SCHIRMANN, K. et al. Technical note: Validation of a system for monitoring rumination in dairy cows. **Journal of Dairy Science**, v. 92, n. 12, p. 6052 – 6055, 2009. ISSN 0022-0302. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022030209713220>>.



SELLA, G. E. Clinical utilization of surface electromyography and needle electromyography: A comparison of the two methodologies. **Biofeedback**, v. 35, n. 1, p. 38–42, 2007. Association for Applied Psychophysiology & Biofeedback.

SMITH, D.; GREENWOOD, P. L. Cattle behaviour classification from collar , halter , and ear tag sensors. **Information Processing in Agriculture**, China Agricultural University, v. 5, n. 1, p. 124–133, 2017. ISSN 2214-3173. Disponível em: <<https://doi.org/10.1016/j.inpa.2017.10.001>>.

SOLNIK, S.; RIDER, P.; STEINWEG, K. Teager – Kaiser energy operator signal conditioning improves EMG onset detection. p. 489–498, 2010.

STASHUK, D. EMG signal decomposition: how can it be accomplished and used? **Journal of Electromyography and Kinesiology**, v. 11, n. 3, p. 151 – 173, 2001. ISSN 1050-6411.

STAUDE, G. et al. Onset detection in surface electromyographic signals: A systematic comparison of methods. **EURASIP Journal on Advances in Signal Processing**, v. 2001, n. 2, p. 867853, Jun 2001. ISSN 1687-6180. Disponível em: <<https://doi.org/10.1155/S1110865701000191>>.

TAM, H.; WEBSTER, J. G. Minimizing electrode motion artifact by skin abrasion. **IEEE Transactions on Biomedical Engineering**, BME-24, n. 2, p. 134–139, March 1977. ISSN 0018-9294.

TAMURA, T. et al. Dairy cattle behavior classifications based on decision tree learning using 3-axis neck-mounted accelerometers. **Animal Science Journal**, n. July 2018, p. 1–8, 2019. ISSN 17400929.

TKACH, D.; HUANG, H.; KUIKEN, T. A. Study of stability of time-domain features for electromyographic pattern recognition. **J Neuroeng Rehabil**, BioMed Central, v. 7, p. 21–21, May 2010. ISSN 1743-0003. 1743-0003-7-21[PII]. Disponível em: <<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC2881049/>>.

TRINDADE, J. K. da. **Comportamento e consumo de forragens de bovinos de corte em pastagem natural complexa**. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, 2011.

TULLO, E.; FINZI, A.; GUARINO, M. Review: Environmental impact of livestock farming and precision livestock farming as a mitigation strategy. **Science of The Total Environment**, v. 650, p. 2751 – 2760, 2019. ISSN 0048-9697. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0048969718338919>>.

ULTRA SOUND ADVICE. **IGER Behaviour Analysis System**. 2014. Website. Products - Custom instrumentation. Disponível em: <<http://www.ultrasoundadvice.co.uk/index.php/grazing-behaviour/grec3-recorder>>.

UNGAR, E. D.; RUTTER, S. M. Classifying cattle jaw movements: Comparing behaviour recorder and acoustic techniques. **Applied Animal Behaviour Science**, v. 98, n. 1–2, p. 11 – 27, 2006. ISSN 0168-1591. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168159105002492>>.

VALENTIN, S.; ZSOLDOS, R. R. Surface electromyography in animal biomechanics: A systematic review. **Journal of Electromyography and Kinesiology**, Elsevier Ltd, v. 28, p. 167–183, 2016. ISSN 18735711. Disponível em: <<http://dx.doi.org/10.1016/j.jelekin.2015.12.005>>.

VIRGILIO, A. di et al. Multi-dimensional Precision Livestock Farming: a potential toolbox for sustainable rangeland management. **PeerJ**, v. 6, n. May, p. e4867, 2018.

VU, T. H.; MONGA, V. Learning a low-rank shared dictionary for object classification. **CoRR**, abs/1602.00310, 2016.

Vu, T. H. et al. Histopathological image classification using discriminative feature-oriented dictionary learning. **IEEE Transactions on Medical Imaging**, v. 35, n. 3, p. 738–751, March 2016. ISSN 0278-0062.

WILLIAMS, S. H. et al. Mandibular corpus bone strains during mastication in goats (*capra hircus*): A comparison of ingestive and rumination chewing. **Archives of Oral Biology**, v. 56, n. 10, p. 960 – 971, 2011. ISSN 0003-9969. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0003996911000604>>.

WILLIAMS, S. H. et al. Masticatory motor patterns in ungulates: a quantitative assessment of jaw-muscle coordination in goats, alpacas and horses. **Journal of Experimental Zoology Part A: Ecological Genetics and Physiology**, Wiley Subscription Services, Inc., A Wiley Company, v. 307A, n. 4, p. 226–240, 2007. ISSN 1932-5231. Disponível em: <<http://dx.doi.org/10.1002/jez.362>>.

WINTER, B. B.; WEBSTER, J. Driven-right-leg circuit design. **IEEE Transactions on Biomedical Engineering**, BME-30, n. 1, p. 62–66, Jan 1983. ISSN 0018-9294.

WOSNIAK, C. et al. **Determination of chewing patterns in goats using fiber Bragg gratings**. 2012. 84214F-84214F-4 p. Disponível em: <<http://dx.doi.org/10.1117/12.974332>>.

XU, Y. et al. A survey of dictionary learning algorithms for face recognition. **IEEE Access**, PP, p. 1–1, 04 2017.

YANG, M. et al. Sparse representation based fisher discrimination dictionary learning for image classification. **International Journal of Computer Vision**, v. 109, p. 209–232, 09 2014.

Yonghong Huang et al. A gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses. **IEEE Transactions on Biomedical Engineering**, v. 52, n. 11, p. 1801–1811, Nov 2005. ISSN 0018-9294.

YOO, H.-J.; PARK, H.-j.; LEE, B. Myoelectric signal classification of targeted muscles using dictionary learning. **Sensors**, v. 19, n. 10, 2019. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/19/10/2370>>.

ZARDOSHTI-KERMANI, M. et al. Emg feature evaluation for movement control of upper extremity prostheses. **Rehabilitation Engineering, IEEE Transactions on**, v. 3, n. 4, p. 324–333, Dec 1995. ISSN 1063-6528.

ZEHNER, N. et al. System specification and validation of a noseband pressure sensor for measurement of ruminating and eating behavior in stable-fed cows. **Computers and Electronics in Agriculture**, v. 136, p. 31 – 41, 2017. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169916306664>>.

Zhang, Z. et al. A survey of sparse representation: Algorithms and applications. **IEEE Access**, v. 3, p. 490–530, 2015. ISSN 2169-3536.

ZHENG, H.; TAO, D. Neurocomputing Discriminative dictionary learning via Fisher discrimination K-SVD algorithm. **Neurocomputing**, Elsevier, v. 162, p. 9–15, 2015. ISSN 0925-2312. Disponível em: <<http://dx.doi.org/10.1016/j.neucom.2015.03.071>>.

## APÊNDICE A – CODIFICAÇÃO ESPARSA

A ideia central dos algoritmos de codificação esparsa é encontrar um vetor esparso que ao ser combinado linearmente com o dicionário reconstrua um sinal de interesse. A esparsidade do sinal pode ser representada pela norma  $\ell_0$ , que é equivalente à cardinalidade, ou seja, o número de elementos não nulos do vetor:

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{sujeito a} \quad \mathbf{y} = \mathbf{D}\mathbf{x}. \quad (35)$$

Uma família de algoritmos que atendem a esse propósito são os algoritmos gulosos (*greedy algorithms*), onde se adiciona uma componente de cada vez, que ao ser multiplicado pela coluna do dicionário irá resultar no menor erro possível. Supondo que se deseje encontrar uma coluna do dicionário que ao ser multiplicada por um escalar produza o menor erro. As ativações podem ser encontradas por  $m$  testes (um por coluna de  $\mathbf{D}$ ), sendo que o  $j$ -ésimo teste por ser feito minimizando  $\epsilon(j) = \|\mathbf{d}_j z_j - \mathbf{y}\|$ , o que leva a  $z_j^* = \mathbf{d}_j^T \mathbf{y} / \|\mathbf{d}_j\|_2^2$ , de forma que a expressão do erro é dada por:

$$\begin{aligned} \epsilon(j) &= \min_{z_j} \|\mathbf{d}_j z_j - \mathbf{y}\|_2^2 = \left\| \frac{\mathbf{d}_j^T \mathbf{y}}{\|\mathbf{d}_j\|_2^2} \mathbf{d}_j - \mathbf{y} \right\|_2^2 \\ &= \|\mathbf{y}\|_2^2 - \frac{(\mathbf{d}_j^T \mathbf{y})^2}{\|\mathbf{d}_j\|_2^2}. \end{aligned} \quad (36)$$

O modelo pode ser generalizado para um vetor  $\mathbf{x}$  com mais de um elemento não nulo, entretanto testar todas as combinações possíveis pode ser inviável computacionalmente. Um algoritmo guloso abandona a estratégia exaustiva e busca soluções locais. Após encontrar a primeira ativação, essa componente é mantida e o algoritmo é executado novamente procurando o segundo componente que reduz o erro. Após a inclusão de uma nova coluna do dicionário, o erro é avaliado e, caso atenda um requisito o algoritmo termina.

Uma estratégia otimizada é o algoritmo de busca por correspondência ortogonal (*Orthogonal Matching Pursuit* ou OMP). Primeiro, inicia-se o algoritmo com  $\mathbf{x}^0 = 0$  e o resíduo inicial  $\mathbf{r}^0 = \mathbf{y} - \mathbf{D}\mathbf{x}^0 = \mathbf{y}$ , de forma que o suporte (argumento dos elementos não nulos de  $\mathbf{x}$ ) é inicializado como  $\mathbf{S}^0 = \text{Suporte}(\mathbf{x}^0) = \emptyset$ . Então calcula-se o erro de forma análoga à Equação 36 trocando  $\mathbf{y}$  pelo resíduo  $\mathbf{r}^{k-1}$ :

$$\begin{aligned} \epsilon(j) &= \min_{z_j} \|\mathbf{d}_j z_j - \mathbf{r}^{k-1}\|_2^2 = \left\| \frac{\mathbf{d}_j^T \mathbf{r}^{k-1}}{\|\mathbf{d}_j\|_2} \mathbf{d}_j - \mathbf{r}^{k-1} \right\|_2^2 \\ &= \|\mathbf{y}\|_2^2 - \frac{(\mathbf{d}_j^T \mathbf{r}^{k-1})^2}{\|\mathbf{d}_j\|_2^2}. \end{aligned} \quad (37)$$

Dessa forma o erro é inversamente proporcional ao produto entre o resíduo e as colunas normalizadas de  $\mathbf{D}$ . Após encontrar o erro de cada  $j$ -ésima componente, escolhe-se o argumento  $j_0$  de  $\epsilon(j) : \forall j \notin \mathbf{S}^{k-1}, \epsilon(j_0) \leq \epsilon(j)$  e o suporte é atualizado  $\mathbf{S}^k = \mathbf{S}^{k-1} \cup \{j_0\}$ .

O termo de erro de  $\|\mathbf{D}\mathbf{x} - \mathbf{y}\|_2^2$ , o qual o suporte é  $\mathbf{S}^k$ , pode ser reescrito considerando apenas a combinação dos termos não nulos. Denotando os termos não nulos do vetor esparsa como  $\mathbf{x}_{\mathbf{S}^k}$  e os átomos do dicionário ativados por esse vetor por  $\mathbf{D}_{\mathbf{S}^k}$ , o termo de erro se torna  $\|\mathbf{D}_{\mathbf{S}^k} \mathbf{x}_{\mathbf{S}^k} - \mathbf{y}\|_2^2$ . A minimização do erro é feita zerando a derivada da expressão quadrática, o que leva a:

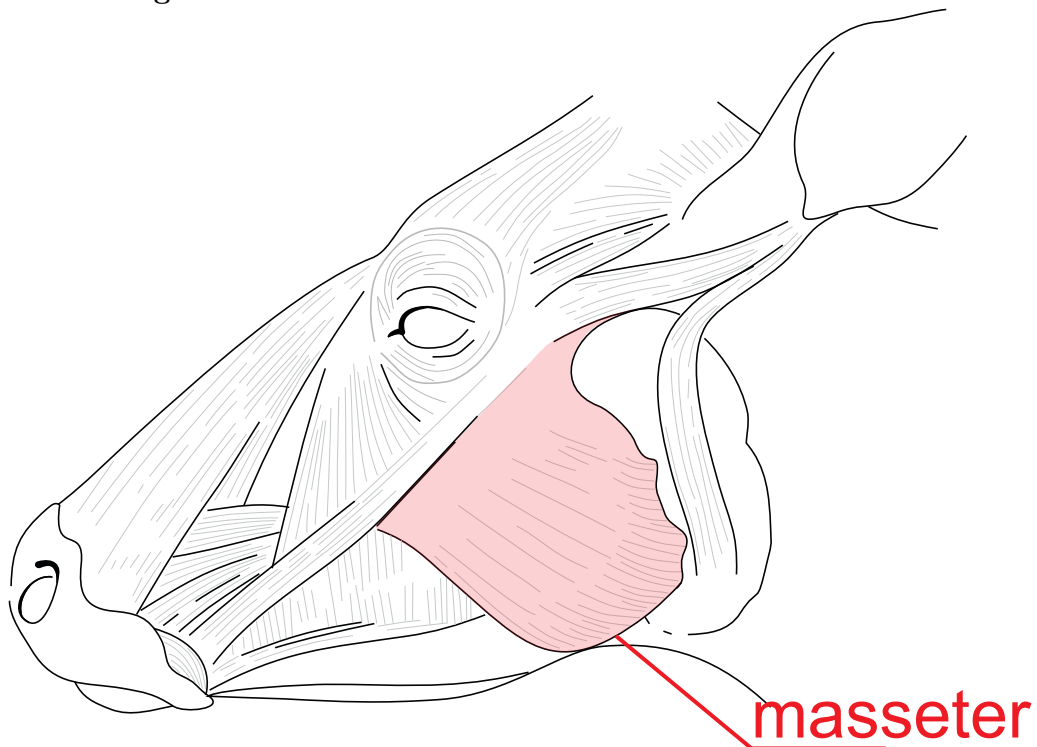
$$\mathbf{D}_{\mathbf{S}^k}^T (\mathbf{D}_{\mathbf{S}^k} \mathbf{x}_{\mathbf{S}^k} - \mathbf{y}) = -\mathbf{D}_{\mathbf{S}^k}^T \mathbf{r}^k = 0. \quad (38)$$

Assim, o resíduo da  $k$ -ésima iteração pode ser atualizado avaliando a expressão acima. Essa relação sugere que os átomos que fazem parte do suporte são necessariamente ortogonais ao resíduo  $\mathbf{r}^k$ , e portanto, essa componente não precisa ser reavaliada na próxima iteração. Esse processo de ortogonalização é a razão do nome do método. O algoritmo itera até que o resíduo atinja um erro permitido pré-determinado.

## APÊNDICE B – ANATOMIA DO MÚSCULO MASSETER

A Figura 33 mostra o detalhe anatômico da região do músculo masseter em um bovino (em destaque) em relação aos demais músculos da face (CUYER; HAYWOOD, 1905).

**Figura 33: Detalhe anatômico do músculo masseter de um bovino.**



Fonte: Adaptado de Cuyer e Haywood (1905)

## APÊNDICE C – EXTRAÇÃO DE CARACTERÍSTICAS USANDO KSVD

Os resultados apresentados abaixo foram apresentados durante a qualificação deste trabalho. Nessa etapa, a classificação de padrões ingestivos foi realizada por uma técnica de aprendizado de dicionário chamada de kSVD. Essa técnica permite o treinamento de um dicionário capaz de codificar e reconstruir um sinal por meio de representação esparsa. O vetor de codificação esparsa foi utilizado como uma característica do sinal e usado conjuntamente com diversos classificadores comumente utilizados para a finalidade de reconhecimento de padrões eletromiográficos.

Inicialmente acreditava-se que a utilização da técnica kSVD por si só poderia ser suficiente para a classificação de padrões ingestivos. Entretanto observou-se que a técnica proposta apresentava desempenho similar às técnicas encontradas na literatura, apresentando as vantagens intrínsecas que os métodos de representação esparsa apresentam. Portanto, se levantou a hipótese de que técnicas de representações esparsas otimizadas para a classificação de imagens poderiam servir ao propósito desejado.

Por mais que essa técnica não apresentou os resultados esperados, as conclusões que foram encontradas tem sua importância, pois alguns dos achados contribuíram para decisões fundamentais no desenvolvimento da técnica proposta, como por exemplo a metodologia de segmentação e a observação de algumas limitações experimentais. Dessa forma diversas modificações foram feitas na metodologia a partir dos dados preliminares, tanto na coleta e tratamento de dados quanto no processamento dos sinais.

### C.1 METODOLOGIA

Foram estudadas duas vacas Jersey com uma idade média de 6,5 ( $\pm 0.025$ ) anos e com peso médio de 460 ( $\pm 21.2$ ) kg. Cada animal confinado e privado de comida por 3 horas. As amostras de alimentos eram compostas por silagem, oferecidas em quantidades variadas com três repetições. A rotulagem dos dados foi obtida por meio de inspeção visual usando gravações de vídeo. Os sinais de sEMG do músculo masseter foram adquiridos

e gravados por um sistema eletrônico alimentado por bateria. Devido às diferenças de quantidade de alimento ofertada, a aquisição de cada repetição variou entre 29 até 168 segundos.

O ganho do amplificador foi ajustado em 6 vezes e o ADC foi configurado para amostrar o sinal em 1 kHz. Nessa frequência, o estágio de filtragem de terceira ordem do ADC garante uma banda de frequência de saída efetiva de 262 Hz<sup>1</sup>

## C.2 SEGMENTAÇÃO

A segmentação dos dados foi feita de três formas: segmentação cega (BS), segmentação de limiar-duplo (DTOS) e segmentação centrada no pico (FLPCS) (JUNIOR et al., 2017). Os métodos de segmentação são ilustrados na Figura 34 e discutidos a seguir.

**Segmentação cega** (*Blind Segmentation* ou **BS**)<sup>2</sup>: uma janela deslizante corta o sinal periodicamente em segmentos de tamanho fixo com sobreposição parcial. É um método mais elementar e aqui será utilizado para testar o sistema de classificação proposto. O  $i$ -ésimo segmento é definido por<sup>3</sup>:

$$\mathbf{s}_i = \{x_{(i-1)k}, \dots, x_{(i-1)k+W}\}, \quad (41)$$

com  $W$  sendo a dimensão do segmento e  $k$  o passo da janela. A fração da janela que fica sobreposta pode ser calculada por  $(W - k)/W$ .

**Segmentação de limiar-duplo** (*Double-Threshold Onset Segmentation* ou **DTOS**): é o método clássico de segmentação encontrado na literatura. Segmenta-se as parcelas do sinal retificado e suavizado que atendam critérios de amplitude e duração mínima (limiares). O tamanho da janela é variável, entretanto pode ser limitada. Supondo que  $y$  seja o sinal original retificado e suavizado:

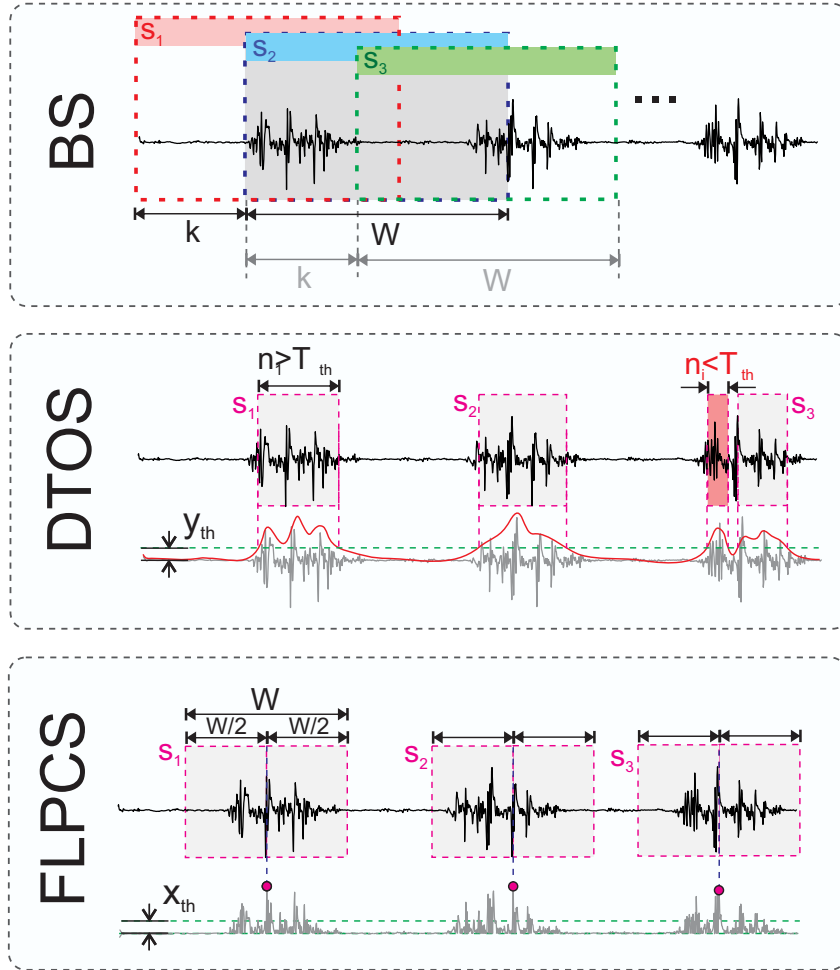
<sup>1</sup>O conversor delta-sigma é baseado em sobreamostragem de conversões de 1 bit cuja demodulação envolve um filtro de decimação. No caso do ADS1298, a frequência de corte é 0.262\*frequência de modulação, e portanto, resultado em 262 Hz.

<sup>2</sup>Esse método é citado na literatura como segmentação por sobreposição ou *overlapping* (quando o passo da janela é menor que sua dimensão) e segmentação disruptiva (quando o passo da janela é maior que sua dimensão), porém como o algoritmo para ambos os métodos é o mesmo, reuniu-se ambos com o nome de segmentação cega devida sua ausência de critério.

<sup>3</sup>Todas as análises se consideram um sinal de sEMG  $\in \mathbb{R}^N$ , sendo composto por uma sequência de dados representado pelo vetor  $\mathbf{x} = [x_1, \dots, x_N]$ .



Figura 34: Métodos de segmentação



Fonte: Autoria própria

$$y = |\mathbf{x}| * \mathbf{k}, \tag{42}$$

sendo  $*$  o operador de convolução,  $\mathbf{k}$  um *kernel* de dimensão  $M$  e  $|\mathbf{x}|$  o sinal retificado<sup>4</sup>. A partir disso define-se a janela de segmentação verificando quando o sinal retificado e suavizado ( $\mathbf{y}$ ) passa de um valor de limiar ( $y_{th}$ ) e quando retorna abaixo do valor limiar e se a dimensão do segmento ( $n_i$ ) é maior que um critério de dimensão mínima ( $T_{th}$ ). Assim, supondo que essa condição seja atendida em um momento  $k_i$ :

<sup>4</sup>Caso o *kernel* seja  $\mathbf{k} = \frac{1}{M} \mathbf{1}$ , sendo  $\mathbf{1}$  um vetor  $\in \mathfrak{R}^M$  preenchido por 1, a operação resulta em média móvel.

$$\begin{aligned}
\mathbf{y}_{k_i} &> y_{th} \\
\mathbf{y}_{k_i+n_i} &< y_{th} \\
n_i &> T_{th},
\end{aligned} \tag{43}$$

de forma que  $\{y_{k_i}, \dots, y_{k_i+n_i-1}\} > y_{th}$ , o  $i$ -ésimo segmento é definido por:

$$\mathbf{s}_i = \{x_{k_i}, \dots, x_{k_i+n_i}\} \tag{44}$$

**Segmentação centrada no pico** (*Fixed Length Peak Centered Segmentation* ou **FLPCS**): apenas segmentam-se as parcelas do sinal que apresentam picos dentro de uma janela fixa. Esse método apresenta algumas vantagens em relação aos métodos atuais, entretanto possui custo computacional mais elevado. Os segmentos são encontrados buscando as janelas do sinal (com índice  $i$ ) que atendam à seguinte condição:

$$i = \underset{x_i > x_{th}}{i \in [1 + \frac{W}{2}, \dots, N - \frac{W}{2}]} \{|x_{i-W/2}|, \dots, |x_{i+W/2}|\}, \tag{45}$$

em que  $W$  representa a dimensão da janela<sup>5</sup>,  $N$  a dimensão do sinal e  $x_{th}$  um limiar definido pelo nível de ruído. Dessa forma os segmentos são definidos por:

$$\mathbf{s}_i = \{x_{i-W/2}, \dots, x_{i+W/2}\}. \tag{46}$$

De maneira alternativa, pode-se encontrar uma matriz  $\mathbf{A}$  de modo que ao operar a multiplicação com um segmento do sinal que atenda o critério de limiar  $\mathbf{s}_i > x_{th}$ , encontre-se um vetor  $\mathbf{b}$  com as diferenças entre cada amostra e o centro, de forma que  $\mathbf{b} = \mathbf{A}\mathbf{s}$ . Essa matriz pode ser definida por  $\mathbf{A} = \mathbf{M} - \mathbf{I}$  em que  $\mathbf{I}$  é a identidade e  $\mathbf{M}$  é dada por:

$$M_{pq} = \begin{cases} 1, & \text{se } q = hW \\ 0, & \text{caso contrário,} \end{cases} \tag{47}$$

em que  $hW$  é metade da dimensão da janela (podendo ser  $W/2$  ou  $(W-1)/2$ ), e  $p$  e  $q$  são as notações de linha e coluna da matriz, respectivamente. Dessa forma, a janela é armazenada como segmento se atende à condição:  $\mathbf{b} > 0$  para todo o vetor, ou seja,

<sup>5</sup>Se  $W$  é par, o segmento terá dimensão  $W+1$ . Caso seja ímpar, deve-se usar  $i \pm (W-1)/2$  como limites da janela e a dimensão do segmento será  $W$ .

se todas as diferenças entre o centro e as amostras adjacentes são positivas. Em caso positivo, pode-se iterar meia janela para frente ( $i = i + hW$ ) e o segmento é definido da mesma forma como anteriormente.

Os parâmetros escolhidos para cada método são descritos a seguir na Tabela 20:

**Tabela 20: Parâmetros usados nos métodos de segmentação**

Método	Janela	Retific.	Suaviz.	Critério
BS	fixa (600 ms)	não	não	passo fixo (300 ms)
FLPCS	fixa (600 ms)	sim	não	amplitude ( $x_{th} = 0,15$ ) máximo centralizado
DTOS	variável	sim	média móvel (50 ms)	amplitude ( $y_{th} = 0,03$ ) duração ( $T_{th} = 100 ms$ )

### C.3 EXTRAÇÃO DE CARACTERÍSTICAS E CLASSIFICAÇÃO

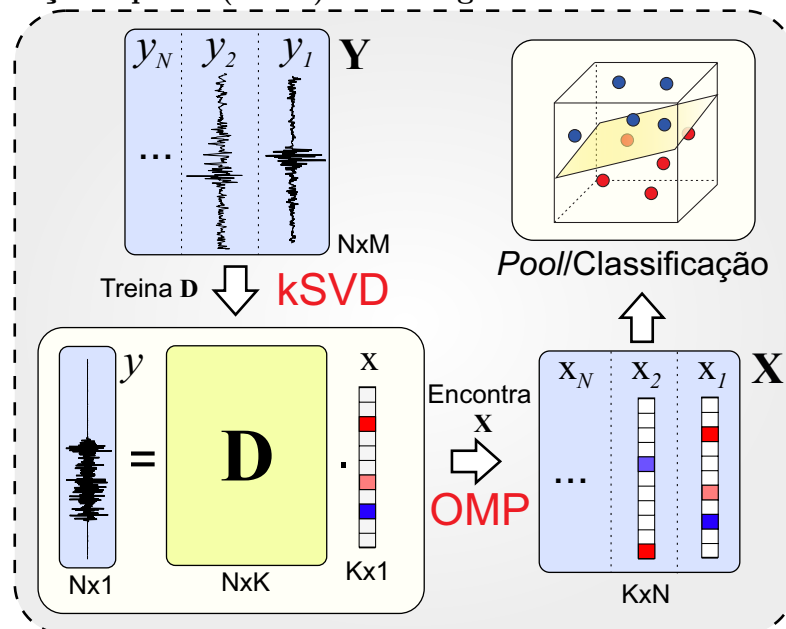
As características extraídas foram usadas como entrada em diversos classificadores comumente usados na literatura: *k-Nearest Neighbors* (k-NN), *Linear Discriminant Analysis* (LDA), *Quadratic Discriminant Analysis* (QDA), *Support Vector Machine* (SVM), *Decision Trees* (DT) e *Naive Bayes* (NB). Os parâmetros dos classificadores foram otimizados e o resultado foi expresso em termos de taxa de acerto. Todos os testes foram submetido à validação cruzada *k-fold* com  $k = 10$ .

Todas as características foram usadas para avaliar os métodos de segmentação. Afim de comparar o desempenho dos classificadores usando características a partir do sinal bruto e reconstruído do conjunto de teste, o número de características foram limitados em duas para que tenha balanço com as duas características extraídas do vetor esparso (média e máximo). Dessa forma evitar-se-ão possíveis polarizações por diferença de dimensionalidade da entrada dos classificadores. As duas características escolhidas foram WL e SSI por sua simplicidade computacional no que tange à facilidade em embarcar o processamento e por serem duas características distintas (SSI é baseado na integração do sinal e WL na soma das diferenças das amplitudes). Ainda, essas características não dependem de critérios de limiar, cuja calibração pode ser uma dificuldade em aplicações em larga escala.

Após segmentar os dados usando o método com melhor desempenho de classificação, obteve-se uma matriz de amostras de sinais de sEMG de movimentos mastigatórios. A partir dessa matriz foram extraídas as características descritas

anteriormente. Além disso, também foram obtidos os vetores esparsos através do método kSVD. As etapas desse processamento é resumida nos blocos da Figura 35. Nessa etapa encontrou-se um dicionário para um conjunto de dados e então os vetores esparsos que codificam o sinal foram calculados para cada segmento de sinal através da OMP. Como os vetores esparsos ainda possuem alta dimensionalidade (porém baixa cardinalidade), uma etapa chama de *Pooling* foi aplicada para redução da dimensão. Duas técnicas comumente usadas na literatura foram usadas, o máximo e a média, em que basicamente encontra-se a maior componente e a média das componentes não-nulas do vetor que codifica o sinal, respectivamente. É esse vetor reduzido que usou-se para finalidades de classificação.

**Figura 35: Extração de características por meio de treinamento de dicionário (kSVD), codificação esparsa (OMP) e Pooling.**

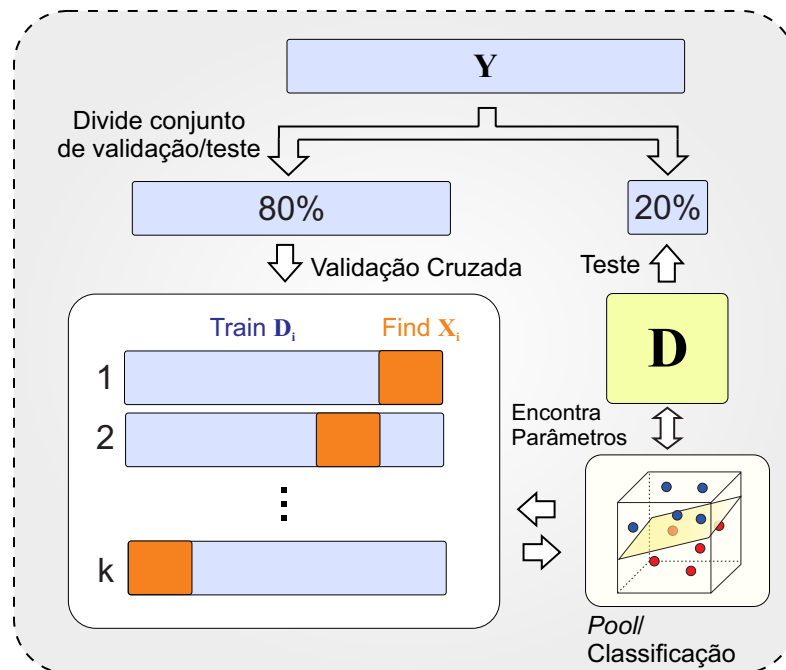


Fonte: Autoria própria

Um esquema de validação cruzada e conjunto de teste foi traçado para avaliar os melhores parâmetros da representação esparsa. O fluxograma desse esquema é mostrado na Figura 36. Foram usados 2000 instâncias ( $\mathbf{Y}$ ), 1000 segmentos de ruminação e 1000 segmentos de alimentação de silagem. Os segmentos foram escolhidos aleatoriamente do processo ingestivo de todos os animais estudados e embaralhados. O conjunto é separado em duas partes, uma de 80% para validação e outra de 20% para teste. Do conjunto de validação, uma parte é separada para treinar o dicionário usando kSVD e outra parte é usada para ser codificada pelo OMP. Esse processo, chamado de validação cruzada k-fold, é repetido com esse conjunto até que todos os dados da validação tenham sido usados para treinar dicionário e para codificação. Nesse trabalho foi escolhido um  $k = 5$ , ou seja,

o processo é repetido 5 vezes dividindo 80% para cada  $i$ -ésimo dicionário  $D_i$  e 20% para cada matriz de códigos esparsos  $X_i$ . Essa matriz é usada para avaliar a qualidade da reconstrução do sinal e a precisão quando usada para reconhecimento de padrões. Esse processo foi repetido alterando os parâmetros do algoritmo kSVD (dimensão e esparsidade do vetor  $x$ ).

**Figura 36: Fluxograma de validação e teste da técnica de extração de características por kSVD.**



Fonte: Autoria própria

Após encontrados os melhores parâmetros, esse conjunto de validação é usado em sua totalidade para treinar um novo dicionário e então o conjunto separado inicialmente é usado para teste.


Os resultados estão divididos em duas partes: segmentação e extração de características. Na primeira parte foram descritos os aspectos qualitativos do sinal segmentado e como as técnicas afetam os resultados de qualificação. Na segunda parte estão os resultados do método kSVD para o conjunto de validação (reconstrução e classificação usando kNN) e teste (classificação usando métodos distintos).

### C.3.1 EFEITO DA SEGMENTAÇÃO NA CLASSIFICAÇÃO

Os resultados da classificação avaliada com diferentes classificadores e métodos de segmentação são mostrados na Figura 37. Os resultados numéricos são expressos

na Tabela 21 onde é mostrado a média e desvio padrão da validação. A precisão da classificação excursionou entre 90 e 95% de forma que o método FLPCS apresentou melhores resultados. Entretanto deve-se ponderar que esse método tem maior custo computacional e pode não ser adequado para aplicações em tempo real. Os métodos DTOS e BS tiveram resultados semelhantes, o que é interessante visto que DTOS exige maior esforço computacional, dessa forma para aplicações *online* o método BS deve ser o mais adequado. Ainda, todos os métodos de classificação parecem ser adequados para esse propósito, embora métodos como kNN e LDA possuam menor complexidade. Os erros podem estar associados à falsos positivos na segmentação ou ainda com o procedimento experimental.

**Figura 37:** Gráfico em barras da taxa de acertos dos classificadores para diferentes métodos de segmentação. Os bigodes nas caixas representam o desvio padrão.



Fonte: Autoria própria

**Tabela 21:** Taxa de acertos e desvio padrão dos classificadores para diferentes métodos de segmentação.

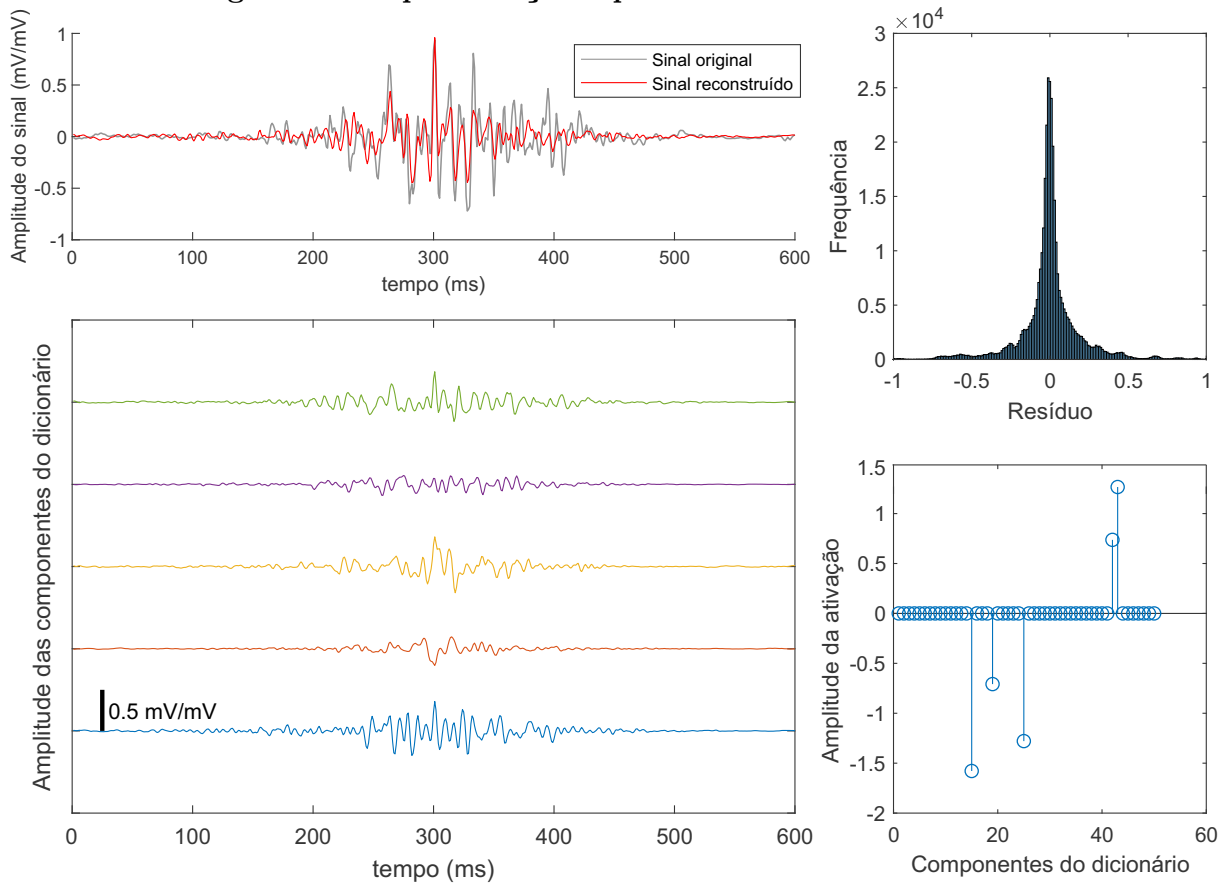
	kNN	LDA	QDA	DT	DB	SVM
FLPCS	92.6% ± 1.9%	90.2% ± 2.3%	92.0% ± 1.6%	92.4% ± 1.2%	91.5% ± 1.2%	93.5% ± 1.8%
DTOS	91.7% ± 2.1%	89.6% ± 2.3%	90.6% ± 2.2%	90.1% ± 1.0%	90.1% ± 1.7%	91.5% ± 1.7%
BS	91.6% ± 1.6%	89.8% ± 2.3%	90.3% ± 2.0%	90.9% ± 1.4%	91.2% ± 1.5%	92.3% ± 1.8%

## C.4 K-SVD

### C.4.1 VALIDAÇÃO

A Figura 38 exibe um exemplo da representação esparsa de um sinal de sEMG. O sinal original é codificado pelo algoritmo OMP e pelo dicionário treinado pela kSVD de forma que a combinação linear dos componentes não-nulos e dos respectivos protótipos ativados reconstróem o sinal. Um histograma da frequência da magnitude dos resíduos (diferença ponto a ponto entre sinal original e construído) mostra a concentração do erro em torno de zero.

**Figura 38: Representação esparsa de um sinal de sEMG.**




**Fonte: Autoria própria**

A dispersão do erro quadrático médio da reconstrução de todos sinais considerados para a validação é mostrado nos diagramas de caixas e bigodes (*boxplots*) na Figura 39 para diversas combinações de parâmetros da dimensão do vetor esparsa ( $K$ ) e número máximo de componentes ( $T$ ). A mediana do erro se situa em valores menores que 0,05, com pouca ou nenhuma diferença entre a escolha de parâmetros, embora alguns *outliers* se espalhem entre 0,15 e 0,25. Essas anomalias podem estar relacionadas a falsos positivos no momento

da segmentação do sinal, ou seja, sinais que não representam movimentos mastigatórios mas que são selecionados pelo algoritmo. Dessa forma, uma limitação dessa representação é a segmentação de sinais *on-line* de sinais de EMG, pouco reportada na literatura. Ainda, o presente trabalho não considerou a utilização de dicionários supercompletos ( $K$  maior do que a dimensão do segmento) para evitar o efeito de *overfitting* (associação de um sinal em cada átomo do dicionário) devido ao baixo número de instâncias. Com uma base de dados maior essa hipótese será testada.

**Figura 39: Erro quadrático médio da reconstrução dos segmentos de sinais de sEMG do conjunto de validação.**




**Fonte: Autoria própria**

A Figura 40 mostra os *boxplots* da taxa de acertos da classificação usando kNN e variando  $K$  e  $T$  usando como características os valores máximos e as médias dos vetores esparsos. Novamente o que se observa é uma pequena diferença entre os parâmetros, sem identificação clara de um padrão. Os resultados não apresentaram diferença significativa ao nível de 5% pelo teste de Kruskal-Wallis. A faixa de dispersão dos resultados se situa entre valores acima de 75% até próximos de 100%. Apesar de apresentarem elevados valores máximos, a técnica apresenta elevada variância.

Para teste foi escolhido  $T = 5$  e  $K = 100$  por apresentar valor máximo e mínimo relativamente alto, além de que é preferível vetores com dimensão reduzido visto que isso



**Figura 40: Dispersões dos resultados de classificação por kNN usando o máximo e a média do vetor esparso variando os parâmetros de esparsidade e dimensão.**




**Fonte: Autoria própria**

impacta no esforço computacional durante o treinamento do dicionário.

A Figura 40 mostra a comparação entre as dispersões dos resultados de classificação (kNN) usando quatro características individualmente. A partir do gráfico podemos notar oscilações entre 80 e 90% e inferir que WL (sinal bruto) e o média (vetor esparso) possuem resultados relativamente melhores, embora não foi observado diferenças significativas entre WL e SSI e entre máximo e média pelo teste de Kruskal-Wallis com significância de 5%.

**Figura 41: Dispersões dos resultados de classificação por kNN usando características individualmente.**



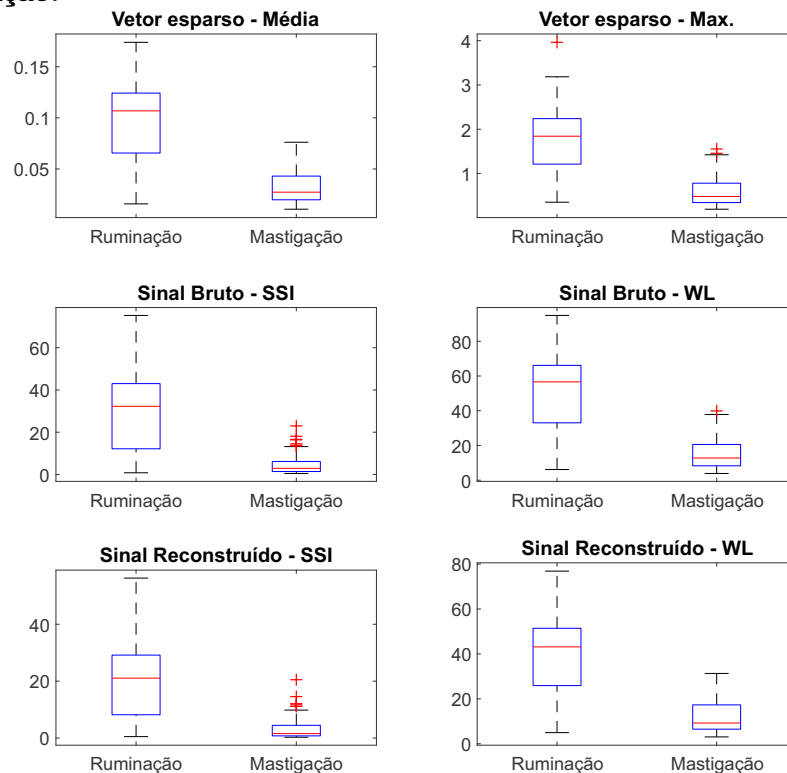
**Fonte: Autoria própria**

### C.4.2 TESTE

A dispersão das características extraídas dos sinais bruto, reconstruído e esparso são exibidos na Figura 42. Observa-se uma diferença entre as duas classes porém com uma região de sobreposição. Isso se deve aos movimentos mastigatórios durante o consumo de silagem com semelhança à ruminação, e.g. parcela do alimento processado com composição de fibras e texturas próximas ao *bolus* ruminal.

Outro aspecto a ser observado é a semelhança entre a dispersão do sinal bruto e construído, o qual indica a capacidade de usar esse sinal na classificação. Em sistemas embarcados existe a dificuldade em transmitir sinais brutos devido à sua alta dimensionalidade e dessa forma a configura uma vantagem a possibilidade de transmitir o vetor esparso, mais compacto, para então reconstruí-lo após a recepção e então processá-lo posteriormente.

**Figura 42: Diagramas de caixas e bigodes da dispersão das características escolhidas para classificação.**

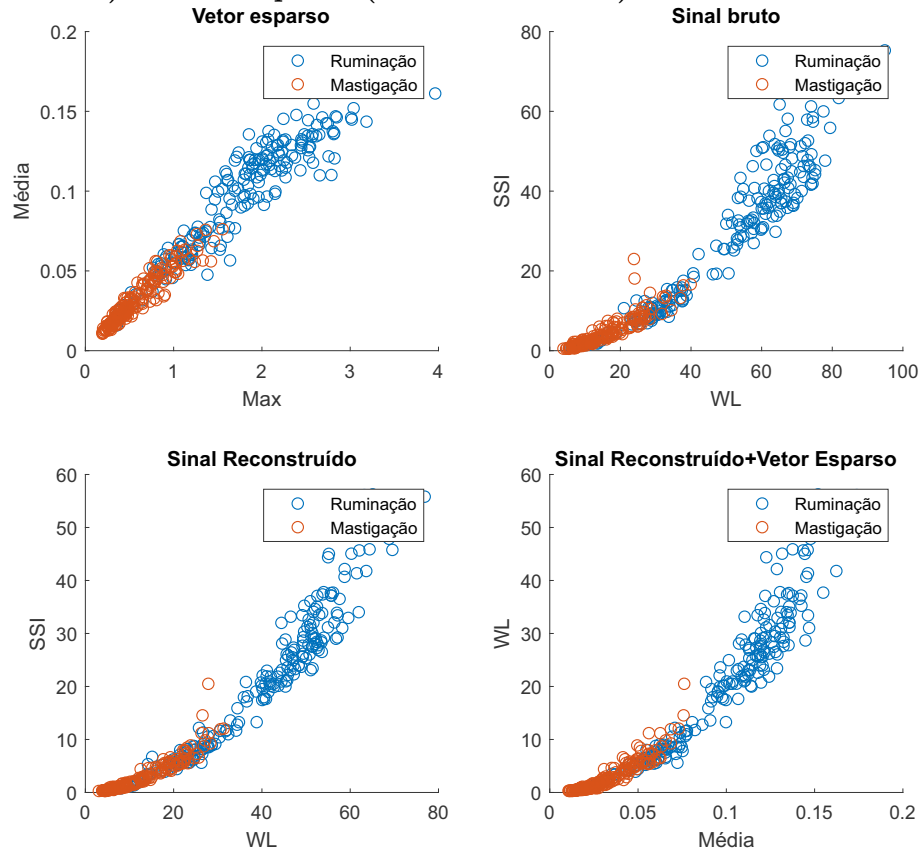


**Fonte: Autoria própria**

A Figura 43 mostra um gráfico bidimensional de dispersão (*scatter plot*) entre duas características: máximo e média do vetor esparso, SSI e WL do sinal bruto e reconstruído e cruzamento entre WL do vetor reconstruído e média do vetor esparso (por apresentarem

melhor desempenho na validação). Fica claro que as duas classes ocupam regiões distintas no plano por mais que exista uma região de sobreposição que inevitavelmente levará à atribuições incorretas na identificação do padrão.

**Figura 43: Dispersão em plano bidimensional entre pares de características do sinal bruto (SSI e WL) e vetor esparso (máximo e média).**




**Fonte: Autoria própria**

Por fim, o resultado da classificação do conjunto de teste usando as combinações mostradas anteriormente é representada do diagrama de barras na Figura 44, onde as linhas verticais representam o desvio padrão. A taxa de acertos de todos os classificadores e combinações se situam entre 80 e 95%. Esses valores não diferem dos valores observados nos conjuntos de validação, demonstrando que o dicionário generaliza sinais não usados para o treinamento. Os métodos não diferem significativamente entre si devido ao desvio padrão relativamente elevado, embora o sinal reconstruído demonstre desempenho menor do que o sinal bruto. O melhor resultado é obtido pelas características do sinal bruto porém o uso do vetor esparso para classificação não deve ser descartado. Portanto, o método se ajustou sem diferenças significativas entre classificadores, o que permite o uso de técnicas de baixo custo computacional como kNN.

Embora a literatura utilize a média e o valor máximo do vetor esparso como

**Figura 44: Diagrama de barras dos resultados da identificação de padrões de ruminção e consumo de silagem para diferentes combinações de características e técnicas de classificação.**



Fonte: Autoria própria

*pooling* para classificação, pode-se questionar se essa forma de redução não descarta informação útil. Uma hipótese a ser testada é se a posição (suporte) das ativações não levam a resultados melhores na classificação. Outra possibilidade é incluir no *pooling* informações sobre o protótipo ativado, como por exemplo realizar o produto entre a ativação e características extraídas diretamente do átomo do dicionário. Ainda, a literatura traz método de otimização do dicionário para maximização da separabilidade classes, chamado de *Label Consistent* kSVD (LC-kSVD) (JIANG et al., 2013), onde o algoritmo otimiza não só o dicionário, mas também o *pooling* e o classificador.

## C.5 CONCLUSÃO

Foram confrontados duas técnicas de extração, uma a partir de cálculos da série temporal dos dados brutos (WL e SSI) e uma nova técnica a partir do vetor esparsos que codifica os sinais por meio de um dicionário treinado por kSVD. As técnicas não apresentaram diferenças significativas, com taxas de acerto acima de 85% usando kNN, LDA, QDA, DT, NB ou SVM.

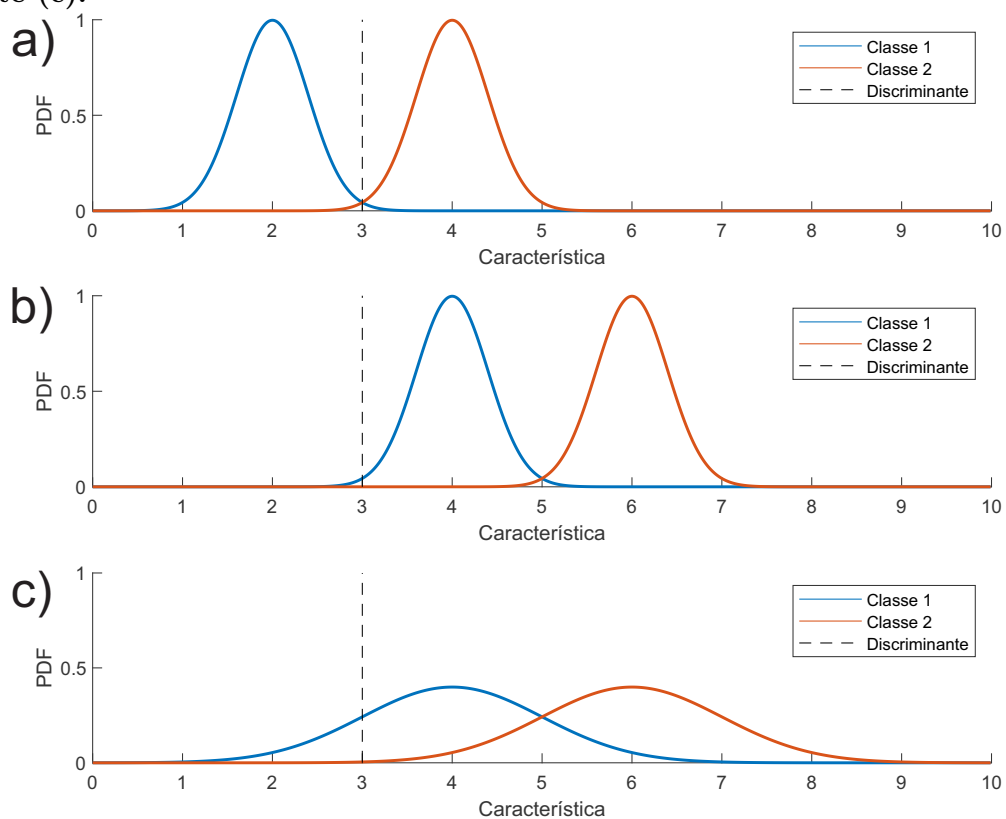
O método de extração com kSVD apresenta uma vantagem quanto à compactação de dados, interessante para finalidade de transmissão remota dos sinais. Os dados de sEMG reconstruídos apresentaram erro reduzido em relação ao sinal original e se mostraram pouca dependência dos parâmetros de esparsidade e dimensionalidade.

Foram avaliados também três técnicas de segmentação: BS, DTOS e FLPCS. A técnica FLPCS apresentou melhores resultados para classificação, embora demande maior esforço computacional. Além disso, observou-se que a segmentação levou a identificação de falsos positivos, ou seja, sinais que não representam movimentos mastigatórios foram considerados produzindo erros anômalos na reconstrução.

## APÊNDICE D – NÃO-MONOTONICIDADE DO ERRO

Como observado nos resultados apresentados nesse trabalho, algumas características apresentam desempenho não-linear em razão da inserção de diferentes níveis de ruído. É esperado que a inserção de ruído deva comprometer de forma monotônica os resultados de classificação, entretanto algumas características podem apresentar um comportamento anormal, não-monotônica. Isso é observado principalmente em características baseadas em contagem, e.g. ZC e SSC.

**Figura 45: Comportamento da classificação de uma característica com variação de média e desvio padrão. O desempenho do classificador treinado para um conjunto de dados (a) é dramaticamente afetado com deslocamento da média das características (b), porém pode apresentar uma melhora anormal de desempenho caso a variância aumente (c).**



Fonte: Autoria própria

Inicialmente, um conjunto com dados limpos é usado para treinamento de um discriminante ideal (Figura 45a). A medida que a relação sinal-ruído dos dados de teste diminui, a distribuição média das características se deslocam, fazendo com que os dados se situem majoritariamente em um dos lados do hiperplano de separação, aqui expresso como uma linha discriminante (Figura 45b), até o ponto em que os dados serão todos atribuídos a uma única classe. Entretanto, se em algum momento as características apresentarem aumento de variância, a cauda da distribuição acabará por voltar a cruzar o plano de separação, aumentando a taxa de acerto do classificador (Figura 45c).

**ANEXO A – PARECER DA COMISSÃO DE ÉTICA NO USO ANIMAL**





Ministério da Educação  
UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
Câmpus Dois Vizinhos  
Comissão de Ética no Uso de Animais - CEUA



PROJETO DE PESQUISA / AULA PRÁTICA

<b>Título:</b>	Identificação De Padrões de Mastigação em Ruminantes Utilizando Eletromiografia de Superfície do Músculo Masseter
<b>Área Temática:</b>	Engenharia
<b>Pesquisador / Professor:</b>	Fabio Luiz Bertotti
<b>Instituição:</b>	Universidade Tecnológica Federal do Paraná - Câmpus Pato Branco - UTFPR-PB
<b>Financiamento:</b>	PROAP
<b>Versão:</b>	001

<b>PARECER CONSUBSTANCIADO DA CEUA</b>	<b>Protocolo nº 2015-002</b>
<b>Apresentação do Projeto:</b>	
Os pesquisadores propõem uma nova técnica para avaliar os padrões de mastigação de ruminantes. A eletromiografia de superfície (sEMG) é capaz de fornecer diversas informações da atividade muscular. Acredita-se que através de sEMG dos músculos da mastigação, sendo o masseter o principal, somado às técnicas de instrumentação, processamento de sinais e classificação de dados, seja possível extrair as variáveis de interesse de maneira automática.	
<b>Objetivo:</b>	
A proposta do presente trabalho é desenvolver um novo método de avaliação automática dos bocados e do padrão de mastigação, para estabelecer o alimento consumido e determinar os tempos de ruminação, alimentação e repouso diário através dos sinais de sEMG do músculo masseter dos animais ruminantes.	
<b>Avaliação dos Riscos e Benefícios:</b>	
Os riscos são mínimos e os pesquisadores indicam técnicas para minimizar o estresse causado pelo aparelho.	
<b>Comentários e Considerações sobre a Pesquisa / Aula Prática:</b>	
Os animais receberão dois eletrodos colados na pele, além disso, receberá um cabresto para melhor fixação. Os pesquisadores indicam que o local será isolado e protegido para que não ofereça risco ao animal. O objetivo dos pesquisadores é que esse sistema (Eletromiografia de superfície) indique diretamente a habilidade de mastigação quanto detectar automaticamente a ingestão de alimentos.	
<b>Considerações sobre os Termos de apresentação obrigatória:</b>	



Ministério da Educação  
UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
Câmpus Dois Vizinhos  
**Comissão de Ética no Uso de Animais - CEUA**



Os termos obrigatórios foram enviados.
<b>Conclusões ou Pendências e Lista de Inadequações:</b> Não há pendências.
<b>Situação do Parecer:</b> APROVADO.

Dois Vizinhos, 16 de março de 2015.

Assinado por:

Patricia Franchi de Freitas

Presidente da Comissão de Ética no Uso de Animais da UTFPR