

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

VINICIUS PEGORINI

**CLASSIFICAÇÃO DE PADRÕES DE MASTIGAÇÃO DE
RUMINANTES UTILIZANDO APRENDIZAGEM DE MÁQUINA**

DISSERTAÇÃO

PATO BRANCO

2015

VINICIUS PEGORINI

**CLASSIFICAÇÃO DE PADRÕES DE MASTIGAÇÃO DE
RUMINANTES UTILIZANDO APRENDIZAGEM DE MÁQUINA**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Engenharia Elétrica” – Área de Concentração: Sistemas e Processamento de Energia.

Orientador: Dr. Rafael Cardoso

Co-orientador: Dr. Richardson Ribeiro

PATO BRANCO

2015

Dados Internacionais de Catalogação

P376c Pegorini, Vinicius

Classificação de padrões de mastigação de ruminantes utilizando aprendizagem de máquina / Vinicius Pegorini. - 2015.

119 f. : il. ; 30 cm.

Orientador: Prof. Dr. Rafael Cardoso.

Co-orientador : Prof. Dr. Richardson Ribeiro.

Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. Pato Branco, 2015.

Bibliografia: f. 103-109.

1. Engenharia elétrica 2. Redes neurais artificiais 3. Comportamento ingestivo I. Cardoso, Rafael, orient. II. Ribeiro, Richardson, co-orient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. IV. Título.

CDD 22. ed.: 621.3

Ficha Catalográfica elaborada por: Leandro Pandini, 2015.

CRB – 9/1473



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Câmpus Pato Branco
Diretoria de Pesquisa e Pós-Graduação
Programa de Pós-Graduação em Engenharia Elétrica



TERMO DE APROVAÇÃO

Título da Dissertação n° 037

CLASSIFICAÇÃO DE PADRÕES DE MASTIGAÇÃO DE RUMINANTES UTILIZANDO APRENDIZAGEM DE MÁQUINA.

por

Vinicius Pegorini

Dissertação apresentada às quatorze horas do dia vinte de agosto de dois mil e quinze, como requisito parcial para obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA. Programa de Pós-Graduação em Engenharia Elétrica (Área de Concentração: Sistemas e Processamento de Energia), Universidade Tecnológica Federal do Paraná, Câmpus Pato Branco. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho APROVADO.

Banca examinadora:

Prof. Dr. Rafael Cardoso
UTFPR/PB (Orientador)

Prof. Dr. Richardson Ribeiro
UTFPR/PB (Coorientador)

Prof. Dr. Fábio Luiz Bertotti
UTFPR/PB

Prof. Dr. Fabrício Enembreck
PUC/PR

Prof. Dr. Tangriani Simioni Assmann
UTFPR/PB

Prof. Dr. Ricardo Vasques de Oliveira
Coordenador do PPGE

*O termo de aprovação assinado encontra-se na coordenação do PPGE

RESUMO

PEGORINI, Vinicius. CLASSIFICAÇÃO DE PADRÕES DE MASTIGAÇÃO DE RUMINANTES UTILIZANDO APRENDIZAGEM DE MÁQUINA. 119 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Pato Branco, 2015.

Este trabalho apresenta um estudo sobre a aplicação de técnicas de aprendizagem de máquina na análise do processo ingestivo de ruminantes, contemplando as etapas de preparação e classificação dos dados. O estudo desenvolvido resultou no desenvolvimento de um sistema utilizado para classificar de maneira automatizada diferentes eventos realizados por ruminantes durante a ingestão de alimentos e também alimentos consumidos pelos animais. Classificar padrões no comportamento ingestivo de ruminantes serve como base para estudos relacionados à nutrição animal bem como a identificação de dados relacionados a saúde animal. Neste trabalho, o conhecimento é obtido por meio da classificação de padrões usando redes neurais artificiais e árvores de decisão. Os dados foram coletados usando sensores a fibra ótica baseados em redes de Bragg (FBG), fixados na mandíbula do animal sob estudo. Foram realizados ensaios *in vitro*, com base em uma mandíbula cadavérica de um caprino, bem como ensaios *in vivo* para análise do processo mastigatório de um bovino da espécie *Bos taurus*. Diferentes tipos de materiais e plantas forrageiras foram usados para medir forças biomecânicas envolvidas no processo de mastigação do alimento. Os dados obtidos nos ensaios são pré-processados e utilizados para o treinamento dos algoritmos de aprendizagem de máquina. Resultados experimentais mostram que é possível classificar diferentes forrageiras e eventos envolvidos no processo ingestivo de ruminantes, contribuindo para melhoria da eficiência da atual metodologia de avaliação de consumo animal.

Palavras-chave: Aprendizagem de máquina, classificação de padrões, redes neurais artificiais, árvores de decisão, comportamento ingestivo.

ABSTRACT

PEGORINI, Vinicius. CLASSIFICATION OF CHEWING PATTERNS OF RUMINANTS USING MACHINE LEARNING. 119 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Pato Branco, 2015.

In this work, a system to automate the classification of chewing patterns of ruminants is developed. Pattern classification of ingestive behavior in grazing animals has extreme importance in studies related to animal nutrition, growing and health. The proposal is based on data collected by optical fiber Bragg grating sensors (FBG). The collected data are processed by machine learning techniques. The FBG sensors measure the biomechanical strain during jaw movements. *In vitro* tests were performed based on a cadaveric mandible of a goat and *in vivo* tests were performed by monitoring the food intake process of a steer. For the pattern classification a classic model of decision tree and artificial neural network were used. Experimental results show that the proposed approaches for pattern classification have been capable to differentiate the materials and events involved in the chewing process. Experimental results show that it is possible to classify different forage and events involved in the ingestive behaviour of ruminants, that contributes to improving the current methodology for monitoring the animal consumption efficiency.

Keywords: Machine learning, pattern classification, artificial neural networks, decision trees, ingestive behaviour.

LISTA DE FIGURAS

FIGURA 1	– Caprinos distribuídos nos piquetes, com fraldas	20
FIGURA 2	– Esquema utilizado para gravação dos dados no método acústico	22
FIGURA 3	– Novilha equipada com microfone conectado ao gravador de áudio digital	23
FIGURA 4	– Fístula esofágica	25
FIGURA 5	– Animal com a fístula esofágica	25
FIGURA 6	– Neurônio natural	34
FIGURA 7	– Neurônio artificial	35
FIGURA 8	– Arquitetura de uma rede MLP	36
FIGURA 9	– Modelo de um perceptron	37
FIGURA 10	– Função sigmoide	38
FIGURA 11	– Função tangente hiperbólica sigmoide	38
FIGURA 12	– Fluxo do sinal do neurônio de saída j	42
FIGURA 13	– Fluxo do sinal do neurônio de saída k conectado ao neurônio oculto j ..	43
FIGURA 14	– Exemplo de uma árvore de decisão	46
FIGURA 15	– Árvore de decisão para o problema de concessão de empréstimo bancário	51
FIGURA 16	– Ilustração da etapa de aquisição dos dados <i>in vitro</i>	55
FIGURA 17	– Crânio cadavérico de caprino utilizado nas simulações de mastigação ..	55
FIGURA 18	– Ilustração das etapas de pré-processamento e classificação dos dados <i>in vitro</i>	56
FIGURA 19	– Histograma das classes <i>in vitro</i>	57
FIGURA 20	– Histograma dos sinais de mastigação <i>in vitro</i>	57
FIGURA 21	– Sinais de mastigação do ensaio <i>in vitro</i>	58
FIGURA 22	– Sinal de mastigação da classe <i>ausência_material</i>	62
FIGURA 23	– FFT dos sinais de mastigação <i>in vitro</i>	63
FIGURA 24	– Sinal de mastigação com marcações indicando as passagens por zero. ..	65
FIGURA 25	– Sinais de mastigação do ensaio <i>in vitro</i>	66
FIGURA 26	– Ilustração das etapas do ensaio <i>in vivo</i>	68
FIGURA 27	– Histograma do conjunto de dados <i>in vivo</i>	70
FIGURA 28	– Histograma dos sinais de mastigação <i>in vivo</i>	70
FIGURA 29	– Sinais de mastigação <i>in vivo</i>	71
FIGURA 30	– Sinais de mastigação dos ensaios <i>in vivo</i>	73
FIGURA 31	– FFT dos sinais de mastigação do ensaio <i>in vivo</i>	75
FIGURA 32	– Estrutura da rede neural para o conjunto de treinamento $\tilde{N}Segmentado_{Vitro}$	76
FIGURA 33	– Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento $\tilde{N}Segmentado_{Vitro}$	83
FIGURA 34	– Conjunto de regras geradas pelo classificador C4.5.	84
FIGURA 35	– Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento $\tilde{N}Segmentado_{FFT_{Vitro}}$	86
FIGURA 36	– Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento $Segmentado_{FFT_{Vitro}}$	89
FIGURA 37	– Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de	

	treinamento <i>Segmentado</i> _{Vivo}	94
FIGURA 38	– Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento <i>Segmentado</i> _{FFT} _{Vivo}	95
FIGURA 39	– <i>Software</i> de aquisição e pré-processamento dos dados. (a) reconhecimento do sensor; (b) diretório onde serão salvos os arquivos gerados; (c) modo de operação; (d) rótulo da classe que está sendo monitorada.	113
FIGURA 40	– Tela de treinamento do classificador.	114
FIGURA 41	– Tela de classificação de novos dados.	115
FIGURA 42	– Diagrama de atividade para as etapas de aquisição, pré-processamento e classificação dos dados.	116

LISTA DE TABELAS

TABELA 1	– Principais técnicas para avaliar o comportamento ingestivo de ruminantes.	26
TABELA 2	– Conjunto de instâncias de pessoas que receberam ou não empréstimo de um banco	29
TABELA 3	– Conjunto de instâncias de treinamento	50
TABELA 4	– Atributos previsores	50
TABELA 5	– Entropia para os valores do atributo valor (a_1).	50
TABELA 6	– Resumo do cálculo do ganho de informação, informação e razão do ganho de informação, para os atributos valor, idade, salário e conta.	51
TABELA 7	– Matriz confusão da RNA com 5 padrões de mastigação - Conjunto de treinamento $\tilde{N}Segmentado_{V_{itro}}$	79
TABELA 8	– Matriz confusão da RNA com 5 padrões de mastigação - Conjunto de treinamento $\tilde{N}SegmentadoFFT_{V_{itro}}$	80
TABELA 9	– Matriz confusão da RNA com 5 padrões de mastigação - Conjunto de treinamento $SegmentadoFFT_{V_{itro}}$	81
TABELA 10	– Resultado geral de erros e acertos nos testes realizados com RNA.	82
TABELA 11	– Matriz de confusão para resultados obtidos através do algoritmo C4.5 utilizando o conjunto de treinamento $\tilde{N}Segmentado_{V_{itro}}$	84
TABELA 12	– Matriz de confusão para resultados obtidos através do algoritmo C4.5 utilizando o conjunto de treinamento $\tilde{N}SegmentadoFFT_{V_{itro}}$	87
TABELA 13	– Matriz de confusão para resultados obtidos com o algoritmo C4.5 utilizando o conjunto de treinamento $SegmentadoFFT_{V_{itro}}$	87
TABELA 14	– Resultado geral de erros e acertos nos testes realizados com Árvore de Decisão.	88
TABELA 15	– Resultado geral de erros e acertos nos testes realizados com RNA e árvore de decisão.	90
TABELA 16	– Matriz confusão da RNA com 5 padrões de mastigação - Conjunto de treinamento $Segmentado_{V_{ivo}}$	91
TABELA 17	– Matriz confusão da RNA com 5 padrões de mastigação - Conjunto de treinamento $SegmentadoFFT_{V_{ivo}}$	92
TABELA 18	– Resultado geral de erros e acertos nos testes realizados com RNAs.	92
TABELA 19	– Matriz de confusão para resultados obtidos através do algoritmo C4.5 utilizando o conjunto de treinamento $Segmentado_{V_{ivo}}$	93
TABELA 20	– Matriz de confusão do conjunto de treinamento $SegmentadoFFT_{V_{ivo}}$ usando o algoritmo C4.5	97
TABELA 21	– Resultado geral de erros e acertos nos testes realizados com árvore de decisão.	97
TABELA 22	– Resultado geral de erros e acertos nos testes realizados com RNA e árvore de decisão.	97
TABELA 23	– Conjunto de instâncias de treinamento	110
TABELA 24	– Resultados de acurácia dos algoritmos de aprendizagem de máquina sobre o conjunto de dados $SegmentadoFFT_{V_{ivo}}$	117

LISTA DE SIGLAS

AM	Aprendizagem de Máquina
AU	Ausência_material
AV	Aveia
AZ	Azevém
CEUA	Comissão de Ética no Uso de Animais
CSV	<i>Comma-Separated Values</i>
FBG	Sensores a fibra ótica baseados em redes de Bragg (<i>Fiber Bragg Grating</i>)
FE	Feno
FFT	Transformada Rápida de Fourier - <i>Fast Fourier Transform</i>
IGER	<i>Institute of Grassland and Environmental Research</i>
MLP	<i>MultiLayer Perceptron</i>
OC	Ócio
PA	Plasticina_A
PB	Plasticina_B
PNG	<i>Portable Network Graphics</i>
RA	Ração
RNA	Rede Neural Artificial
RU	Ruminação

LISTA DE SÍMBOLOS

D	Conjunto de Dados D .
\bar{D}_i	Instância i do conjunto de dados D .
h	Hipótese sobre a função conceito f .
f	Função conceito.
x_m	Terminais de entrada de um neurônio artificial.
w_{km}	Peso associado a um neurônio k .
$\varphi(\cdot)$	Função de ativação.
ϵ_{med}	Valor médio do erro quadrático.
η	Taxa de aprendizagem.
$\delta_j(n)$	Gradiente local.
α	Termo <i>momentum</i> .
$ D_i $	Cardinalidade do conjunto de dados classificados na i -ésima partição.
$ D $	Cardinalidade do conjunto de dados D .
$C_{in vitro}$	Conjunto de atributos classe do ensaio <i>in vitro</i> .
$\tilde{N}Segmentado_{V_{itro}}$	Conjunto de treinamento com os dados originais.
$\overline{\tilde{N}Segmentado}_{V_{itro}i}$	Instância do conjunto de treinamento $\tilde{N}Segmentado_{V_{itro}}$.
$\tilde{N}SegmentadoFFT_{V_{itro}}$	Conjunto de treinamento com os dados originais e FFT.
$\overline{\tilde{N}SegmentadoFFT}_{V_{itro}i}$	Instância do conjunto de treinamento $\tilde{N}SegmentadoFFT_{V_{itro}}$.
$SegmentadoFFT_{V_{itro}}$	Conjunto de treinamento com os dados segmentados e FFT.
$\overline{SegmentadoFFT}_{V_{itro}i}$	Instância do conjunto de treinamento $SegmentadoFFT_{V_{itro}}$.
$C_{in vivo}$	Conjunto de atributos classe do ensaio <i>in vivo</i> .
$Segmentado_{V_{ivo}}$	Conjunto de treinamento com os dados segmentados.
$\overline{Segmentado}_{V_{ivo}i}$	Instância do conjunto de treinamento $Segmentado_{V_{ivo}}$.
$SegmentadoFFT_{V_{ivo}}$	Conjunto de treinamento com os dados segmentados e FFT.
$\overline{SegmentadoFFT}_{V_{ivo}i}$	Instância do conjunto de treinamento $SegmentadoFFT_{V_{ivo}}$.

SUMÁRIO

1 INTRODUÇÃO	12
1.1 DEFINIÇÃO DO PROBLEMA	14
1.2 HIPÓTESES	14
1.3 OBJETIVOS	16
1.3.1 Contribuições do trabalho	16
1.4 ORGANIZAÇÃO DO TRABALHO	17
2 AVALIAÇÃO DO COMPORTAMENTO INGESTIVO DE RUMINANTES	18
2.1 COMPORTAMENTO INGESTIVO DOS RUMINANTES	18
2.2 MÉTODOS DIRETOS DE OBSERVAÇÃO	19
2.3 MÉTODOS INDIRETOS DE OBSERVAÇÃO	21
2.4 CONSIDERAÇÕES FINAIS	26
3 APRENDIZAGEM DE MÁQUINA	28
3.1 FUNDAMENTOS DE APRENDIZAGEM DE MÁQUINA	28
3.1.0.1 Aprendizagem supervisionada	31
3.2 TÉCNICAS DE APRENDIZAGEM DE MÁQUINA	32
3.2.1 Redes Neurais Artificiais	32
3.2.1.1 Conceitos fundamentais	33
3.2.1.2 Neurônios artificiais	34
3.2.1.3 Arquiteturas de Rede: Redes neurais de múltiplas camadas (MLP)	35
3.2.1.4 Algoritmo <i>back-propagation</i>	38
3.2.2 Árvores de Decisão	46
3.2.2.1 Algoritmo ID3	47
3.2.2.2 Algoritmo C4.5	47
3.2.2.3 Processo de construção de árvores de decisão	48
3.3 CONSIDERAÇÕES FINAIS	53
4 METODOLOGIA	54
4.1 AQUISIÇÃO DOS DADOS <i>In vitro</i>	54
4.1.1 Geração dos conjuntos de treinamento	56
4.2 AQUISIÇÃO DOS DADOS <i>In vivo</i>	66
4.2.1 Geração dos conjuntos de treinamento	69
4.3 APLICAÇÃO DOS ALGORITMOS DE APRENDIZAGEM DE MÁQUINA	75
4.4 CONSIDERAÇÕES FINAIS	77
5 RESULTADOS EXPERIMENTAIS	78
5.1 RESULTADOS DOS ENSAIOS <i>In vitro</i>	78
5.1.1 Resultados obtidos com o uso de RNA	78
5.1.1.1 Resultados para o conjunto de treinamento $\tilde{N}Segmentado_{V_{itro}}$	78
5.1.1.2 Resultados para o conjunto de treinamento $\tilde{N}Segmentado_{FFT_{V_{itro}}}$	80
5.1.1.3 Resultados para o conjunto de treinamento $Segmentado_{FFT_{V_{itro}}}$	81
5.1.2 Resultados obtidos com o uso de Árvore de Decisão	82
5.1.2.1 Resultados para o conjunto de treinamento $\tilde{N}Segmentado_{V_{itro}}$	82
5.1.2.2 Resultados para o conjunto de treinamento $\tilde{N}Segmentado_{FFT_{V_{itro}}}$	85

5.1.2.3 Resultados para o conjunto de treinamento <i>SegmentadoFFT_{Vitro}</i>	87
5.1.3 Resultados gerais para o experimento <i>In vitro</i>	89
5.2 RESULTADOS DOS ENSAIOS <i>In vivo</i>	90
5.2.1 Resultados obtidos com o uso de RNA	90
5.2.1.1 Resultados para o conjunto de treinamento <i>SegmentadoVivo</i>	90
5.2.1.2 Resultados para o conjunto de treinamento <i>SegmentadoFFT_{Vivo}</i>	91
5.2.2 Resultados obtidos com o uso de Árvore de Decisão	92
5.2.2.1 Resultados para o conjunto de treinamento <i>SegmentadoVivo</i>	93
5.2.2.2 Resultados para o conjunto de treinamento <i>SegmentadoFFT_{Vivo}</i>	94
5.3 RESULTADOS GERAIS PARA O EXPERIMENTO <i>In vivo</i>	97
5.4 CONSIDERAÇÕES FINAIS	98
6 CONCLUSÃO E CONSIDERAÇÕES FINAIS	99
6.1 PUBLICAÇÕES	101
REFERÊNCIAS	103
Apêndice A – Exemplo de cálculo da razão do ganho de informação	110
Apêndice B – Automatização dos processos de aquisição e classificação dos dados ...	112
Apêndice C – Resultados dos algoritmos de aprendizagem de máquina	117
Anexo A – Parecer da comissão de ética no uso de animais (ceua)	118

1 INTRODUÇÃO

A produção animal é uma importante atividade para o fornecimento de alimentos para o consumo humano. Dentre os principais animais criados para produção de alimentos destacam-se os ruminantes. Os ruminantes como, por exemplo, os bovinos, são animais que possuem como principal característica sua capacidade de transformação gastrintestinal de compostos de células vegetais não consumíveis pelo homem, tais como celulose e hemicelulose, em alimentos como carne e leite (BERCHIELLI et al., 2006).

O sistema de produção dos ruminantes no Brasil é realizado principalmente com a utilização de pastagens na alimentação animal. O uso de pastagens e de forragens na alimentação de ruminantes é uma das principais e mais rentáveis alternativas de exploração do fator produtivo da terra. Entretanto, para se ter benefícios do uso dessa técnica para a produção de animais é fundamental compreender o ambiente de pastagens e a relação planta/animal. Para garantir o melhor entendimento dos animais em ambiente de pastejo e o aumento de produtividade são necessárias inovações e melhorias nas técnicas de manejo dos animais e das pastagens. O resultado do aprimoramento das técnicas para avaliação do comportamento alimentar de ruminantes possui como objetivo prático otimizar a produção e melhorar a rentabilidade do produtor (BERCHIELLI et al., 2006).

A avaliação do consumo de forragem e do comportamento ingestivo de animais é importante para a compreensão dos processos envolvidos no sistema de pastejo (UNGAR, 1996). Um dos objetivos do estudo do comportamento ingestivo animal consiste em avaliar a qualidade da alimentação e, assim, selecionar forrageiras ¹ que resultam em aumento de ganho de peso ou melhoria de outros índices zootécnicos (JOCHIMS et al., 2010).

O monitoramento do consumo de alimentos pelos ruminantes ajuda a determinar a produtividade das pastagens e é, também, uma importante medida de impacto dos animais nos ecossistemas pastoris, podendo influenciar na agricultura e pecuária de precisão (CARVALHO et al., 2009). O monitoramento das atividades de consumo de alimentos também fornece

¹Forrageira: diz-se de uma planta, geralmente herbácea, que pode servir de alimento de animais no pasto ou colhidas e guardadas, para posterior uso.

indicações sobre a saúde e o bem-estar do animal (CLAPHAM et al., 2011). Desta forma, torna-se relevante o uso de abordagens que permitam identificar diferentes aspectos envolvidos no processo de pastejo de ruminantes.

Tipicamente, o manejo de animais, no que tange a sua alimentação em pastagem, é bastante empírico (SILVA et al., 2009). Diversas técnicas vêm sendo empregadas para avaliação do comportamento de animais em ambientes de pastejo, sendo o método acústico a principal delas (LACA et al., 1992; CLAPHAM et al., 2011). Essa técnica faz uso de sensores de áudio para obter dados sobre os movimentos mandibulares dos animais durante o período de pastejo. Possui como vantagem a não necessidade de procedimentos cirúrgicos para implantação dos sensores nos animais, isto é, é uma técnica não invasiva. No entanto, existem algumas desvantagens, tais como: interferências nas amostras de áudio, dificuldade na análise dos dados e ausência de automatização no processo de classificação dos dados. Uma técnica similar é o método *IGER*, que também utiliza amostras de áudio para coletar dados relacionados com o comportamento ingestivo de ruminantes (UNGAR; RUTTER, 2006).

Outra alternativa, amplamente utilizada, é a observação direta, em que observadores coletam os dados de bocado e mastigação durante o processo de alimentação dos animais. Nessa técnica, a maior parte do processo é realizada de maneira manual, desde a coleta dos dados até a inserção dos dados em programas de computadores para gerar dados estatísticos. (MEZZALIRA et al., 2011). Há ainda uma técnica baseada na análise do ganho de peso, a qual utiliza fraldas geriátricas para reter as fezes e urina, e também permite avaliar o comportamento ingestivo dos animais durante o processo de pastejo (SILVA et al., 2009).

Apesar de existirem diversos métodos para avaliar o comportamento ingestivo de ruminantes, poucos apresentam técnicas automatizadas para aquisição e classificação desses dados. Este trabalho propõe a aplicação de técnicas de aprendizagem de máquina para automatização do processo de classificação de dados relacionados ao processo ingestivo de ruminantes. As técnicas de aprendizagem de máquina são aplicadas na classificação de padrões em diferentes tipos de plantas forrageiras, bem como nos eventos envolvidos no processo de alimentação de ruminantes. Foram realizados experimentos *in vitro* e *in vivo* utilizando-se de sensores à fibra ótica baseado em redes de Bragg (FBG) para aquisição dos dados de mastigação. Os sensores FBG possuem biocompatibilidade e imunidade eletromagnética, permitindo a coleta de dados livre de ruídos externos além de serem capazes de detectar mínimas movimentações do maxilar do animal em estudo (CARVALHO et al., 2006).

1.1 DEFINIÇÃO DO PROBLEMA

Devido a ausência de automatização dos métodos estudados para a coleta e análise de dados, os métodos atuais podem apresentar falta de precisão nos resultados e também demandar trabalho manual por parte dos pesquisadores.

No método acústico, que é o principal método utilizado nas pesquisas com ruminantes, os dados são coletados por sensores de áudio, porém a classificação muitas vezes é realizada de maneira manual, ocasionando exaustão aos pesquisadores (LACA; WALLISDEVRIES, 2000). Em grande parte dos estudos, o uso de programas de computador para classificar amostras de áudio não permite diferenciar as forrageiras utilizadas durante o pastejo, sendo computados apenas os eventos de bocado e mastigação (LACA et al., 1992; RUTTER, 2000). Já no método de observação direta, os próprios pesquisadores são responsáveis por anotar manualmente os dados durante o período de pastejo. Essa atividade normalmente é demorada, pois a coleta de dados é realizada durante longos períodos de tempo e, posteriormente, organizados de maneira manual (MEZZALIRA et al., 2011).

Assim, o processo de classificação de padrões dos eventos envolvidos no comportamento ingestivo de ruminantes necessita de processos que permitam a coleta dos dados com o mínimo de interferências externas ao período de alimentação do animal e que permitam o processamento e a classificação dos dados de maneira automatizada.

1.2 HIPÓTESES

O processo de aquisição de dados relacionados aos diferentes eventos envolvidos no comportamento ingestivo de ruminantes bem como a identificação de diferentes tipos de alimentos utilizados na nutrição animal podem ser realizados por meio de sensores óticos. Wosniack et al. (2012) avaliaram a viabilidade do uso de sensores FBG aplicados na classificação de padrões de mastigação de ruminantes em ensaios *in vitro*. Sensores óticos são biocompatíveis, isto é, não há rejeição do organismo devido ao material (sílica) não ser tóxico (CARVALHO et al., 2006). O sensor é quimicamente estável, imune a interferência eletromagnética, possui dimensões reduzidas com diâmetro e comprimento na ordem de micrômetros e milímetros, respectivamente, e provê excelente sensibilidade para aquisição de sinais de baixa intensidade (CARVALHO et al., 2006). Outra característica importante é a possibilidade de monitoração em regiões irregulares como, por exemplo, ossos da face, onde é difícil a aplicação de extensometria elétrica convencional (CARVALHO et al., 2006). Esses fatores possibilitam o uso de sensores FBG em experimentos *in vivo* (AL-FAKIH et al., 2012;

ABUSHAGUR et al., 2014).

A partir dos dados adquiridos por sensores a fibra ótica, técnicas de aprendizagem de máquina podem ser utilizadas a fim de classificar os dados do processo ingestivo dos ruminantes. Técnicas de aprendizagem de máquina são utilizadas normalmente para resolver diversos problemas de classificação de dados, como na análise de dados na área médica (MOHANTY et al., 2013; AZAR; EL-METWALLY, 2013), na detecção de fraudes em transações de cartão de crédito (KHANDANI et al., 2010), em sistemas de detecção de intrusão (SANGKATSANEE et al., 2011), no reconhecimento de caracteres (AMIN; SINGH, 1998), de padrões em amostras de áudio (SKOWRONSKI; HARRIS, 2006), entre outras aplicações (DUDA et al., 2000). Portanto, o emprego de aprendizagem de máquina pode permitir a construção de sistemas computacionais capazes de adquirir conhecimento, utilizando-se de conjuntos de dados existentes para melhorar seu desempenho em uma tarefa de classificação (MITCHELL, 1997).

Na aprendizagem de máquina, diversos métodos se destacam: árvores de decisão (QUINLAN, 1993); redes neurais artificiais (HAYKIN, 2001); máquinas de vetores de suporte (CORTES; VAPNIK, 1995); *naive bayes* (CHARNIAK, 1991); aprendizagem baseada em instâncias (AHA et al., 1991), entre outras.

Dentre as possibilidades da escolha de um método de aprendizagem de máquina, o tipo de dados, a velocidade de convergência, a facilidade de implementação, etc. devem ser observados. Redes neurais artificiais (RNA) e árvores de decisão são métodos que podem ser empregados na classificação de padrões em diversas áreas (FENG et al., 2011; JUNGUO et al., 2013; CHO; KURUP, 2011; MOHANTY et al., 2013). Estes métodos são capazes de lidar com atributos categóricos e contínuos, possuem boa velocidade na classificação dos dados e possuem boa tolerância a dados ruidosos, além de permitir trabalhar com aprendizagem supervisionada (RUMELHART; MCCLELLAND, 1986; HAYKIN, 2001; QUINLAN, 1993).

Os algoritmos de redes neurais artificiais podem ser utilizados em diversos problemas de classificação de dados como, por exemplo, no reconhecimento de imagens, de fala, na classificação de dados provenientes de diferentes tipos de sensores (HAYKIN, 2001). Os algoritmos de árvores de decisão também são capazes de classificar dados oriundos de diferentes fontes e podem tratar até mesmo dados ruidosos (QUINLAN, 1993).

O uso de técnicas de aprendizagem de máquina em conjunto com sensores FBG pode melhorar a coleta e classificação dos dados referentes ao comportamento ingestivo de ruminantes. Os dados gerados pela classificação podem ser utilizados no processo de avaliação do comportamento alimentar dos animais, permitindo aos pesquisadores da área de nutrição

animal avaliar as melhores formas de manejo dos animais em ambientes pastoris, visando o aumento da produção animal.

1.3 OBJETIVOS

O objetivo principal desse trabalho é desenvolver um sistema capaz de auxiliar profissionais das áreas de zootecnia, veterinária e agronomia, que trabalham com nutrição animal, na classificação dos eventos envolvidos no processo ingestivo de ruminantes, mais especificamente nas atividades de mastigação e ruminação. Define-se, então, um conjunto de objetivos específicos que devem ser alcançados para o desenvolvimento do trabalho proposto:

- Verificar a viabilidade do uso de dados de sensores FBG para classificação de eventos envolvidos no processo ingestivo de ruminantes;
- Utilizar técnicas de aprendizagem de máquina para classificação dos dados;
- Realizar o processamento dos sinais, visando à identificação de diferentes tipos de alimentos utilizados na nutrição de ruminantes;
- Identificar o evento de ruminação durante o processo ingestivo de ruminantes;
- Comparar o desempenho classificatório obtido através do uso de redes neurais artificiais e árvores de decisão;
- Desenvolver um sistema capaz de processar e gerar saídas padronizadas dos dados oriundos dos sensores FBG;
- Apresentar uma metodologia mais eficiente alternativa as atuais metodologias utilizadas para avaliação de consumo animal.

1.3.1 CONTRIBUIÇÕES DO TRABALHO

A principal contribuição tecnológica deste trabalho é disponibilizar um sistema automatizado para a classificação de padrões do comportamento ingestivo de ruminantes com dados coletados por sensores FBG, os quais são imunes à interferências externas e são biocompatíveis.

Como contribuição científica, foram empregadas técnicas de aprendizagem de máquina para o treinamento dos classificadores, eliminando a etapa manual na classificação dos dados. Uma outra contribuição, não menos importante, é o processo de instrumentação do sensor e

aquisição dos dados, que foi realizado em um projeto paralelo ao de classificação dos dados, mas que pode ser utilizado em trabalhos futuros para obtenção de outros parâmetros que possam ser utilizados durante a avaliação do comportamento ingestivo de ruminantes.

A abordagem proposta pode ser utilizada pelos pesquisadores da área de nutrição animal para melhor avaliar o comportamento dos animais em ambiente de pastejo, permitindo aprimoramentos no manejo dos animais e das pastagens. Dessa maneira, tanto o setor pecuário quanto o de agricultura podem se beneficiar desse estudo, sendo uma importante contribuição ambiental.

1.4 ORGANIZAÇÃO DO TRABALHO

Este trabalho está dividido em seis capítulos, sendo esta Introdução o primeiro deles. Os demais capítulos estão organizados da seguinte forma:

- No Capítulo 2 é apresentada uma revisão da literatura sobre as principais técnicas utilizadas para avaliar o comportamento ingestivo de ruminantes;
- No Capítulo 3 é apresentada uma visão geral de Aprendizagem de Máquina, bem como alguns conceitos e definições de redes neurais artificiais e árvores de decisão;
- No Capítulo 4 é apresentada a etapa de coleta dos dados e também a criação dos classificadores utilizando redes neurais artificiais e árvores de decisão;
- No Capítulo 5 são apresentados os resultados experimentais obtidos utilizando redes neurais artificiais e árvores de decisão;
- No Capítulo 6 são apresentadas as conclusões do trabalho, bem como as sugestões de trabalhos futuros.

2 AVALIAÇÃO DO COMPORTAMENTO INGESTIVO DE RUMINANTES

Neste capítulo são apresentadas as principais técnicas utilizadas para análise do comportamento de ingestão de alimentos por ruminantes. O consumo de alimentos por animais em pastejo sofre a influência de três grupos de fatores: i) aqueles que afetam o processo de digestão de alimento, que podem estar relacionados com o nível de maturidade da forragem, seu valor nutritivo e digestibilidade; ii) fatores que afetam o processo de ingestão de alimentos, os quais se relacionam com a facilidade de apreensão e colheita da forragem durante o processo de pastejo; e iii) fatores que afetam as necessidades nutricionais e a demanda por nutrientes, os quais estão relacionados com o estágio fisiológico e o nível de desempenho dos animais (HODGSON, 1990).

As técnicas utilizadas na avaliação do comportamento ingestivo de ruminantes foram desenvolvidas a partir de métodos diretos de monitoração, onde os dados eram obtidos por meio do comportamento digestivo dos animais. Os métodos diretos avaliam o consumo de forragem pelo animal, principalmente na avaliação da diferença de peso do animal antes e depois do pastejo ou ao peso de massa de forragem consumida. Posteriormente, as técnicas adotaram como base os métodos indiretos de observação como, por exemplo, o método acústico, o uso de sensores mecânicos, fístula esofágica, entre outros. Nos métodos indiretos são avaliados fatores indiretamente relacionados à nutrição animal como, por exemplo, o número de bocados, o tempo de pastejo e a composição química das fezes. Tais técnicas são apresentadas no decorrer deste capítulo, juntamente com suas características e as possíveis vantagens e desvantagens.

2.1 COMPORTAMENTO INGESTIVO DOS RUMINANTES

O comportamento ingestivo dos ruminantes se divide nas tarefas de ingestão (pastejo e ingestão de outros tipos de alimento), ruminação e ócio (DESWYSEN et al., 1993; FISCHER et al., 2000, 2002). Monitorar ruminantes durante o pastejo é tema de diversas pesquisas na área de nutrição animal. As características estruturais das plantas forrageiras permitem determinar o grau de pastejo seletivo exercido pelos animais, auxiliando na análise da eficiência com a

qual a forragem é colhida. Portanto, as variações das plantas forrageiras que ocorrem durante o processo de pastejo podem influenciar de forma relevante o consumo de forragem pelos animais (CARVALHO et al., 1999). Os vários tipos de forrageiras utilizadas durante o processo de pastejo podem oferecer diferentes quantidades e tipos de nutrientes ingeridos pelos animais (BERCHIELLI et al., 2006).

Outra característica importante que deve ser observada no processo ingestivo de ruminantes é a ruminação. Durante a alimentação o animal realiza uma rápida mastigação para reduzir as dimensões do alimento, facilitando o processo de deglutição. Então, o alimento ingerido é transportado para o rúmen. A ruminação inicia quando o animal regurgita o bolo alimentar gerado pelo rúmen à boca, e realiza a remastigação desse bolo. Nesse processo, o bolo alimentar é fragmentado em partículas menores que irá favorecer o melhor aproveitamento do alimento pelo animal, exercendo efeito importante no processo de consumo e também ao bem-estar. O processo de ruminação está fortemente relacionado com o tipo de forrageiras utilizadas na alimentação, que pode aumentar ou diminuir o tempo de ruminação.

Outros fatores que podem influenciar no tempo de ruminação são situações de estresse, por exemplo, sensação de dor, doenças ou condições do ambiente de pastejo, ou ainda o desconforto, podendo ser causado pela necessidade de longas caminhadas para captação de alimentos ou água (SOEST, 1994; BERCHIELLI et al., 2006). Como o consumo de alimento e o processo de ruminação possuem forte influência no ganho de peso e bem-estar de ruminantes, diversas técnicas foram desenvolvidas para avaliar o comportamento ingestivo desses animais.

2.2 MÉTODOS DIRETOS DE OBSERVAÇÃO

Os métodos diretos de observação fazem a análise de características como quantidade de alimento consumido, peso dos animais antes e após as refeições. Nesses estudos também são comparados dados referentes a quantidade de alimento consumido e a quantidade de matéria fecal eliminada pelo animal após o pastejo.

Nos estudos realizados por Silva et al. (2009), foi adotado um método direto de observação, sendo feita uma análise de ganho de peso durante o período de pastejo. Nesse método, se faz necessária a presença de um humano para a monitoração do animal durante o período de pastejo. Além de demandar grandes extensões de área, tal procedimento demanda longos períodos de observação e todo registro de dados se dá de forma manual e em períodos pré-definidos de tempo. Os dados obtidos são, posteriormente, processados para gerar relatórios com diversos dados acerca do comportamento alimentar e de ganho de peso do animal.

No trabalho realizado por Silva et al. (2009), três avaliadores foram responsáveis pela coleta das informações referentes aos períodos de pastejo e não pastejo. Durante o período de pastejo foram anotados o número de bocados com um contador manual. Os dados foram inseridos manualmente em um programa de análise estatística com o objetivo de identificar o tempo e a frequência dos eventos realizados.

Santos (2009) também avaliou o comportamento ingestivo por meio do método direto de observação em conjunto com a análise do ganho de peso. O procedimento foi realizado em caprinos. O objetivo desse estudo foi verificar o comportamento alimentar do animal na espécie forrageira capim-tanzânia (*Panicum maximum cv. Jacq.*). Nesse estudo foi realizada a verificação da massa de forragem coletada pelo animal durante o pastejo. Para isso, foi analisado o consumo instantâneo real do animal, para o qual foram colocadas fraldas geriátricas nos animais para reter as fezes e urina, como mostrado na Figura 1. Então, os animais foram pesados e submetidos ao pastejo.



Figura 1: Caprinos distribuídos nos piquetes para análise do comportamento ingestivo. (a) animais em pastejo. (b) animais preparados para avaliação de consumo.

Fonte: Santos (2009).

No trabalho de Santos (2009), os eventos de bocado foram contados manualmente durante o processo de pastejo. Após esse processo, os animais foram pesados novamente e, por meio da diferença de pesos, foi estimado o consumo instantâneo do animal. Na etapa seguinte do processo, as fraldas foram substituídas e focinheiras foram colocadas nos animais para evitar o consumo de forragem. Nesse processo, foi calculada a perda metabólica do animal. Desta maneira, o pesquisador calculou o consumo instantâneo real do animal, somando o consumo instantâneo e a perda metabólica do animal. Também foi observada a taxa de consumo instantâneo, sendo calculada por meio do produto entre número de bocados por unidade de tempo e a quantidade de forragem apreendida por bocado (massa de bocado). Este último termo foi medido por meio das diferenças no tamanho das plantas, as quais foram medidas antes e após

o pastejo. Com base nos dados coletados na pesquisa, o autor foi capaz de determinar a melhor forma de manejo dos animais no ambiente de pastejo.

As técnicas que avaliam o ganho de peso podem ser viáveis em análises realizadas em curtos períodos de tempo, entretanto, com o aumento do tempo de monitoração, pode gerar algumas incertezas nos dados coletados. Tipicamente, quanto maior a janela de tempo adotada entre as medidas da diferença de peso, maior a influência dos erros relacionados às perdas com atividades, tais como respiração, defecação, micção e atividades metabólicas. Podem entrar nas estimativas de erro os dados relacionados a ingestão de matéria líquida ou outras não relacionadas com a forragem. Adicionalmente, há erros que podem ser ocasionados por falha humana durante a monitoração dos eventos envolvidos no processo de pastejo (BERCHIELLI et al., 2006).

2.3 MÉTODOS INDIRETOS DE OBSERVAÇÃO

Nos métodos indiretos de observação o comportamento ingestivo dos ruminantes é avaliado, principalmente, por meio da observação dos eventos de mastigação, bocado e ruminação. Para monitorar tais eventos os pesquisadores utilizam-se de sensores ou da observação visual. O uso de métodos indiretos de observação é reportado em Chambers et al. (1981) e Champion et al. (1998), no qual sensores mecânicos são empregados para avaliar os movimentos das mandíbulas dos animais, podendo assim classificar os movimentos de bocado e mastigação.

Laca et al. (1992) empregaram o método acústico para identificar o comportamento de bovinos durante o processo de pastagem. Nesse estudo foram analisados o número de bocados e a densidade do alimento ingerido. Para analisar a densidade do alimento ingerido foram coletadas as medidas de altura do pasto antes e após a pastagem. Para controlar a altura da pastagem os autores construíram placas de madeira com furos, pelos quais foram inseridos o pasto. Os movimentos de bocados foram contados manualmente. Simultaneamente, os dados de áudio do pastejo foram coletados através do uso de microfone e transmissor sem fio.

Todo o ensaio realizado por Laca et al. (1992) foi filmado. A gravação de áudio e vídeo foi necessária, pois somente a contagem visual, realizada por meio de um observador, era imprecisa. Pois muitas vezes, os animais ainda estavam mastigando enquanto realizavam um novo movimento de bocado. Neste trabalho, os pesquisadores foram capazes de diferenciar os diferentes movimentos realizados durante o processo de pastejo, comparando os dados coletados de forma visual com as amostras de áudio e vídeo. Porém, todo esse procedimento de

comparação dos dados foi realizado de forma manual. A Figura 2 mostra, simplificada, o procedimento empregado na preparação do ensaio proposto pelos autores.

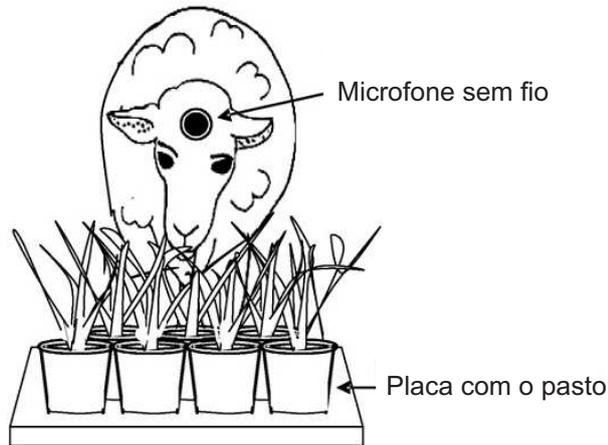


Figura 2: Esquema utilizado para gravação dos dados no método acústico.

Fonte: Milone et al. (2009).

Laca et al. (1994) fazem uso de uma abordagem semelhante à anterior para identificar o comportamento de bovinos durante o tempo de manipulação do alimento, verificando os diferentes eventos envolvidos no processo. No estudo também foram disponibilizadas placas com pasto construídas a mão para alimentação dos animais. Laca et al. (1994) examinaram os movimentos de bocado, mastigação e ruminação. Todos os movimentos foram contados manualmente e, após a realização dos ensaios, foram confirmados através das amostras de áudio e vídeo coletadas. Nesse estudo foi observado que o tempo de mastigação aumentou linearmente de acordo com o aumento de volume de pastagem capturado pelo animal. Outro fator observado no trabalho foi que o tempo de mastigação de cada animal pode sofrer pequenas variações.

Com base na análise acústica, Galli et al. (2006) monitoraram e quantificaram o comportamento de mastigação com o objetivo de estimar o consumo de forragem. O estudo foi conduzido com quatro plantas forrageiras, as quais foram dadas aos animais em diferentes teores de concentração de água (seca e fresca) e também foram adotados dois tamanhos (inteiro e picados). Nesse estudo, foram coletadas amostras de áudio em conjunto com a gravação de vídeo. Os dados foram processados por meio de programas manipuladores de arquivos de áudio, porém o processo de diferenciar os movimentos de mastigação dos diferentes tipos de materiais foi realizado de maneira manual. Durante o processamento dos dados algumas amostras tiveram que ser descartadas, pois foram encontrados ruídos nas amostras analisadas. Nos resultados obtidos observou-se que a diferença de teor de água presente nos diferentes

alimentos utilizados influenciou nas amostras de áudio.

Trindade (2011) fez uso do método acústico em conjunto com a técnica dos alcanos (DOVE; MAYES, 1991). Nesse estudo, o objetivo foi avaliar as relações entre comportamento ingestivo, consumo de forragem, oferta diária de forragem e estrutura do pasto. A Figura 3 mostra a aplicação do sensor de áudio em um dos animais estudados. O método acústico foi utilizado, principalmente, para avaliar o tempo diário nas atividades de consumo de forragem, sendo acompanhados apenas os processos de pastejo e ruminação. O tempo em que o animal não estava em pastejo ou ruminando foi considerado como outras atividades. Nesse trabalho, foi necessário um pesquisador treinado para trabalhar em um programa para tratamento de áudio a fim de processar os dados coletados.

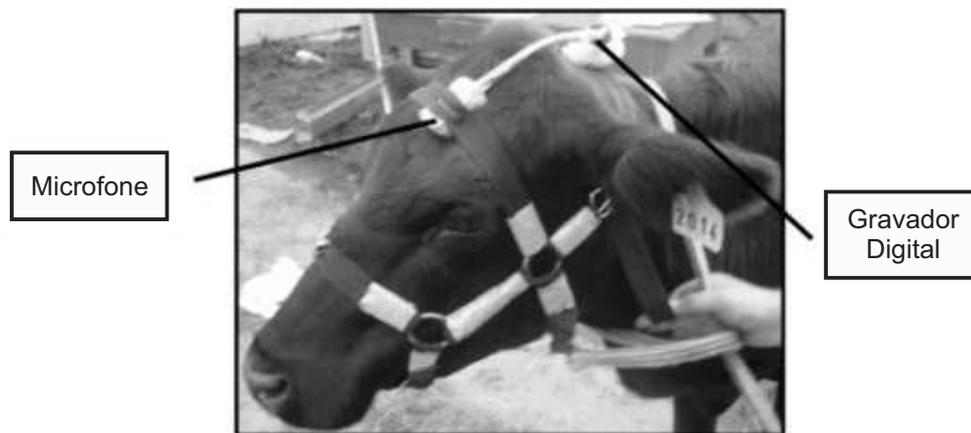


Figura 3: Novilha equipada com microfone conectado ao gravador de áudio digital.

Fonte: Trindade (2011).

Trindade (2011) comparou os dados obtidos a partir o método acústico com os dados coletados manualmente por um observador, evidenciando diferenças nos resultados. Por exemplo, o tempo coletado manualmente para ruminação foi de 102 minutos. Já as amostras de áudio, após o tratamento dos dados, contabilizaram 146 minutos de ruminação. O tempo coletado por meio do método acústico para as amostras de outras atividades foi de 170 minutos, enquanto na coleta manual foi de 208 minutos.

No processo de pastejo também houve diferenças de tempo observado entre os métodos. No método acústico foram observados 365 minutos de pastejo e no manual 371 minutos. Os valores computados para cada atividade mostram que o método acústico obteve maior precisão apenas na análise do tempo de pastejo.

Outra técnica adotada pelos pesquisadores é o método *IGER Behaviour Recorder* (RUTTER et al., 1997). Nesse método um aparelho registra amostras de áudio contendo

os movimentos mandibulares do animal. Essas amostras são processadas pelo programa *Graze Analysis Program* (RUTTER, 2000), que identifica os eventos de bocado e movimentos mandibulares de não bocado. Ungar e Rutter (2006) compararam o método *IGER* com o acústico para monitorar os eventos de bocado, mastigação e períodos sem atividade, em bovinos. Os resultados obtidos pelas duas técnicas foram capazes de diferenciar os três eventos. Os resultados obtidos com o método acústico se apresentaram mais precisos que os obtidos pelo método *IGER*. Porém, no método acústico os procedimentos de classificação dos eventos foram realizados de maneira manual. Outro fator que limita o uso do método *IGER* é que seu desenvolvimento foi descontinuado pelo fabricante (ADVISE, 2014).

Com o objetivo de melhorar o processo de classificação dos eventos ingestivos de ovinos em amostras de áudio, Milone et al. (2009) propuseram uma abordagem computacional utilizando modelos ocultos de *Markov*. Nesse estudo, foram realizados experimentos para diferenciar dois tipos de plantas forrageiras em dois diferentes tamanhos. Para a coleta dos dados, ilustrada na Figura 2, um microfone sem fio foi fixado na testa do animal e as plantas fornecidas para alimentação foram colocadas em recipientes fixados sobre uma base de madeira. Algumas amostras de áudio coletadas pelos microfones possuíam ruídos, provocados por sons vocais emitidos pelos animais e sons provenientes da movimentação dos animais pelo pasto. O resultado geral obtido por tal técnica mostra que o sistema foi capaz de classificar corretamente 82% dos casos de eventos de bocado e mastigação nas duas forrageiras fornecidas.

Outro trabalho para automatizar o processo de classificação de dados em eventos ingestivos foi realizado por Clapham et al. (2011), onde foi utilizado um programa de processamento de áudio. Nesse estudo, não foram classificados os tipos de forrageiras durante o processo de pastejo, mas apenas foram identificados padrões em eventos de bocado e mastigação de bovinos.

Mezzalira et al. (2011) realizaram observação direta dos animais durante o pastejo para medir o comportamento ingestivo. Nesse método, os animais são colocados no ambiente de pastagem, enquanto observadores anotam os eventos de bocado, mastigação, bem como a frequência e o tempo de pastejo. Posteriormente, os dados são processados manualmente pelos pesquisadores. Nesse estudo, foram analisados apenas os tempos de pastejo, ruminação e outras atividades. Essa técnica pode ser exaustiva para observadores, dificultando a coleta de dados e a precisão das observações por longos períodos de tempo, principalmente no período noturno.

Uma outra maneira de observar o comportamento ingestivo de ruminantes é por meio da técnica da fístula esofágica. Esta técnica consiste na realização de um procedimento cirúrgico em um animal, no qual ele é sedado por anestesia e é realizada uma incisão no esôfago para a

instalação de uma cânula, como mostrado na Figura 4. Esta cânula é responsável pelo desvio do alimento para uma bolsa coletora, como exibido na Figura 5. Posteriormente, os dados sobre alimentação são analisados através do material recolhido na bolsa coletora (BARRETO, 2007). Nesse trabalho os resultados mostraram que os animais comportaram-se normalmente após o procedimento cirúrgico permitindo futuras análises dos alimentos consumidos.



Figura 4: Fístula esofágica. (a) incisão no animal. (b) colocação da cânula no esôfago do animal.

Fonte: Barreto (2007).



Figura 5: Animal com a fístula esofágica. (a) o animal com a bolsa coletora. (b) o animal se alimentando com a bolsa coletora.

Fonte: Barreto (2007).

A Tabela 1 apresenta os principais eventos que cada técnica é capaz de identificar. É possível observar que o método acústico é capaz de identificar os principais eventos envolvidos no processo ingestivo de ruminantes. Porém, este método necessita de automatização e melhorias no processo de identificação de diferentes forrageiras. Adicionalmente a presença de ruídos nas amostras de áudio podem comprometer os resultados. Os demais métodos adotam

pouco ou nenhum processo de automatização, sendo sempre acompanhados da observação direta. Ou seja, um ou mais observadores devem estar presentes durante os experimentos para contagem do tempo e monitorar os eventos de bocado e mastigação.

Tabela 1: Principais técnicas para avaliar o comportamento ingestivo de ruminantes.

	Eventos de Mastigação	Ruminação	Identificar Forrageiras	Tempo Pastejo	Massa Consumida
Método Acústico	x	x	x	x	
<i>IGER Behaviour Recorder</i>	x			x	
Fístula Esofágica			x		x
Análise do Ganho de Peso					x
Observação Direta	x	x	x	x	x

Wosniack et al. (2012) propuseram uma abordagem para automatizar o processo de classificação de padrões em movimentos mastigatórios de caprinos. Esse estudo utilizou sensores a fibra ótica baseados em redes de Bragg (FBG) para coleta de dados referentes a mastigação e utilizou redes neurais artificiais para classificação dos dados. Nesse estudo, foram classificados dois tipos de materiais simulando forrageiras utilizadas na alimentação de ruminantes.

O trabalho de Wosniack et al. (2012) mostrou a possibilidade do uso de sensores óticos para a monitoração dos movimentos mastigatórios e resultados preliminares foram encorajadores no que tange a automação do processo de classificação. Assim, esta dissertação visa ampliar o estudo em cima deste tema, buscando o desenvolvimento de um sistema computacional capaz de classificar mais padrões mastigatórios a partir de dados oriundos de sensores óticos baseados em FBG. Como os sensores FBG são imunes a interferência eletromagnética o método proposto permitirá a aquisição de dados livres de interferências externas a processo de mastigação do animal. O sensor FBG também provê excelente sensibilidade para aquisição de sinais de baixa intensidade, permitindo a identificação das diferentes plantas forrageiras utilizadas na nutrição animal.

2.4 CONSIDERAÇÕES FINAIS

Neste capítulo foram abordadas as principais técnicas empregadas para monitorar o comportamento ingestivo de ruminantes. Como foi possível observar, atualmente, o método acústico é uma das principais técnicas para avaliação do comportamento ingestivo de ruminantes. Entretanto, poucos estudos propuseram abordagens para classificação automática dos dados de mastigação de alimentos. Esse processo de classificação automática dos

dados pode ser realizado com o uso de abordagens computacionais por meio de técnicas de aprendizagem de máquina.

O uso de sensores FBG para aquisição dos dados de mastigação e a classificação dos dados por meio de técnicas de aprendizagem de máquina podem melhorar os resultados bem como permitir a automação de parte do processo de análise dos dados.

No Capítulo 3 são apresentados os conceitos e algumas técnicas de aprendizagem de máquina que podem ser aplicadas na classificação de padrões relacionados ao comportamento ingestivo de ruminantes.

3 APRENDIZAGEM DE MÁQUINA

Neste capítulo são apresentados os conceitos fundamentais sobre aprendizagem de máquina, com luz à aprendizagem indutiva, onde um sistema de aprendizagem tem como base exemplos e contraexemplos para criação de hipóteses. Estas, geralmente formadas por conjuntos de regras, podem ser utilizadas para solução de um problema de classificação de padrões.

No trabalho em questão, técnicas de aprendizagem de máquina foram usadas para classificação de padrões de mastigação de ruminantes. Diferentes alimentos e eventos presentes durante o processo de ingestão de alimentos por ruminantes foram classificados por meio de duas técnicas de aprendizagem de máquina, as quais serão abordadas no decorrer deste capítulo.

3.1 FUNDAMENTOS DE APRENDIZAGEM DE MÁQUINA

A Aprendizagem de Máquina (AM) tem como objetivo o desenvolvimento de métodos e técnicas computacionais capazes de adquirir novos conhecimentos, novas habilidades e meios para organizar os conhecimentos já existentes (MITCHELL, 1997). Segundo Fischler e Firschein (1987): *Conhecimento se refere a dados armazenados ou a modelos utilizados por uma pessoa ou máquina para interpretar, prever e responder apropriadamente ao mundo exterior.*

Para a aquisição de novos conhecimentos, as técnicas de aprendizagem de máquina devem ser capazes de criar, baseadas em experiências passadas, uma hipótese capaz de resolver um problema de classificação. A este processo de indução de uma hipótese, baseada na experiência passada, dá-se o nome de aprendizagem de máquina (MITCHELL, 1997). Um exemplo de hipótese pode ser dado na forma de uma regra ou conjunto de regras para definir o perfil de clientes de uma revenda de carros que devem receber propaganda de um novo automóvel. Para tal tarefa são consultados dados de compras passadas dos clientes cadastrados na base de dados da revenda.

O conjunto de dados presente na Tabela 2 será utilizado para ilustrar a relação entre aprendizagem de máquina e indução de hipóteses. Esse conjunto de dados representa exemplos de pessoas que podem ou não terem realizado empréstimos bancário. Cada linha da tabela representa um exemplo (também chamada de instância, padrão ou registro)¹ que corresponde a um cliente. A instância é formada por valores de características ou atributos referentes a dados de empréstimos realizados. Os atributos nome, telefone, valor, idade, salário e se este possui ou não conta no banco são as características dos clientes e são denominados atributos de entrada (também chamados atributos previsores, campos ou variáveis). No caso do empréstimo, é considerado um atributo de saída (também chamado de atributo alvo, meta ou classe)². Os valores associados a esse atributo correspondem a situações já ocorridas, rotulando pessoas que foram categorizadas como aptas ou não aptas a receber empréstimos.

Tabela 2: Conjunto de instâncias de pessoas que receberam ou não empréstimo de um banco

instância	nome	telefone	valor	idade	salário	conta	empréstimo
1	João da Silva	834 5564	médio	sênior	baixo	sim	não
2	José Oliveira	834 9436	médio	sênior	baixo	não	não
3	Márcia Barros	834 3322	baixo	sênior	baixo	sim	sim
4	Thaís Santos	834 8392	alto	média	baixo	sim	sim
5	Carla Almeida	834 4652	alto	jovem	alto	sim	sim
6	Paulo Chaves	834 2512	alto	jovem	alto	não	não
7	Marcelo Assis	834 8861	baixo	jovem	alto	não	sim
8	Ana Carvalho	828 8194	médio	média	baixo	sim	não
9	Diego Santos	828 1215	médio	jovem	alto	sim	sim
10	Mário Silveira	828 1456	alto	média	alto	sim	sim
11	Carlos Machado	834 1749	médio	média	alto	não	sim
12	Kátia Alencar	834 1050	baixo	media	baixo	não	sim
13	Manoel Moreira	828 8910	baixo	sênior	alto	sim	sim
14	Rober Salvador	828 7347	alto	média	baixo	não	não

Fonte: Adaptado de Russel e Norvig (2004).

O conjunto de dados da Tabela 2 pode ser adotado para indução de hipóteses, sendo denominado conjunto de treinamento. Um algoritmo de aprendizagem de máquina aplicado em tarefas de classificação de padrões deve ser capaz de aprender, a partir de um conjunto de treinamento, e criar regras capazes de relacionar os valores dos atributos previsores de uma instância do conjunto de treinamento aos valores de seu atributo classe. O algoritmo de aprendizagem responsável pela geração de hipóteses é chamado de indutor (MICHALSKI et

¹No decorrer do trabalho será utilizado o termo instância devido ser o mais utilizado na literatura de aprendizagem de máquina.

²No decorrer do trabalho será utilizado o termo classe devido ser o mais utilizado na literatura de aprendizagem de máquina.

al., 1986).

Muitas vezes se faz necessária a escolha dos atributos mais relevantes ao processo de classificação. Por exemplo, na classificação dos clientes aptos ou não a receber empréstimo, os atributos referentes ao nome e telefone do cliente não são consideradas entradas relevantes, uma vez que não possuem relação alguma com a concessão ou não do empréstimo. O que se deseja nesse exemplo é induzir uma hipótese (na forma de regra) capaz de classificar novos clientes como aptos ou não ao empréstimo, ou seja, uma vez induzida uma hipótese é desejável que esta seja válida para novas instâncias.

A capacidade de uma hipótese continuar a ser válida para novas instâncias chama-se capacidade de generalização da hipótese. Quando uma hipótese possui uma baixa capacidade de generalização, pode haver um superajuste aos dados (*overfitting*), ou seja, a hipótese se especializou nos dados do conjunto de treinamento. No caso inverso, o algoritmo de aprendizagem de máquina pode induzir hipóteses que apresentem uma baixa taxa de acerto, mesmo no subconjunto de treinamento, configurando uma condição de subajustamento (*underfitting*) (MITCHELL, 1997).

Os algoritmos de aprendizagem de máquina dependem fortemente da extração de conhecimento para realizarem o processo de aprendizagem. Um dos métodos mais adotados para extrair conhecimento e classificar novos dados é a inferência indutiva, a qual faz uso de um conjunto de exemplos conhecidos para derivar novos conhecimentos (MITCHELL, 1997; ALPAYDIN, 2004).

Na aprendizagem de máquina indutiva, um conjunto de instâncias, também chamado de conjunto de treinamento, é empregado para indução de hipóteses capazes de retornar uma solução para um problema proposto. A aprendizagem de máquina costuma distinguir três casos de aprendizagem: aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço (MITCHELL, 1997; RUSSEL; NORVIG, 2004).

Na aprendizagem supervisionada, cada instância utilizada no treinamento deve possuir obrigatoriamente uma classe associada, a qual é adotada na criação do sistema de aprendizagem. Este tipo de aprendizagem será detalhado na subseção 3.1.0.1. Na aprendizagem não supervisionada, as instâncias não possuem classe correspondente. Neste caso, o indutor analisa as instâncias fornecidas e tenta determinar se elas podem ser agrupadas. Então, a análise dos dados é realizada por meio dos agrupamentos criados (THEODORIDIS; KOUTROUMBAS, 2008). Na aprendizagem por reforço, o sistema de aprendizado deve aprender a escolher as ações interagindo com o ambiente (SUTTON; BARTO, 1998).

Após definida a estratégia de aprendizagem, define-se o paradigma de aprendizagem de máquina a ser utilizado, os quais são brevemente apresentados a seguir (MITCHELL, 1997):

- Paradigma estatístico: consiste na adoção de modelos estatísticos para encontrar uma aproximação da hipótese induzida assumindo que os dados possuem distribuição normal;
- Paradigma simbólico: os sistemas baseados no paradigma simbólico realizam o processo de aprendizagem por meio da análise de exemplos e contraexemplos, os quais geralmente estão representados na forma de expressão lógica, árvore de decisão e redes semânticas;
- Paradigma baseado em exemplos: nesse paradigma não é construído um modelo explícito com o conjunto de exemplos. Sistemas desenvolvidos com esse paradigma armazenam os exemplos e adotam medidas de similaridade para identificar os casos mais similares ao exemplo a ser classificado;
- Paradigma conexionista: o conexionismo baseia-se em construções matemáticas inspiradas em conexões neurais do sistema nervoso humano. As redes neurais artificiais são exemplos de técnicas baseadas nesse paradigma;
- Paradigma genético: as técnicas desenvolvidas nesse paradigma são inspiradas pela teoria de Darwin, na qual os indivíduos mais adaptados sobrevivem. Nesse sentido, um algoritmo genético consiste em um procedimento iterativo que mantém uma população de indivíduos, onde cada um é candidato à solução de algum problema específico.

Neste trabalho serão abordados dois algoritmos de aprendizagem de máquina. O primeiro utiliza a técnica de redes neurais artificiais, baseado no paradigma conexionista. O segundo algoritmo é fundamentado na técnica de árvore de decisão, a qual pertence ao paradigma simbólico. A escolha das técnicas está relacionada ao tipo de dados adquiridos dos sensores FBG, os quais fornecem dados contínuos. Outro fator que influenciou a escolha dos algoritmos foi a dimensionalidade do conjunto de dados. Durante a aquisição dos dados, para obter um conjunto de dados com um número significativo de informações é necessário que os dados sejam coletados com taxa de aquisição de 1000 amostras por segundo, o que permite uma análise mais criteriosa das características de cada movimento de mastigação realizado pelo animal.

3.1.0.1 APRENDIZAGEM SUPERVISIONADA

Na aprendizagem supervisionada é fornecido ao sistema de aprendizagem um conjunto de instâncias de treinamento (exemplos) $D = \{\bar{D}_1, \bar{D}_2, \dots, \bar{D}_m\}$, sendo que $\bar{D}_i \in D$, e possui

um rótulo associado. Esse rótulo define a classe a qual a instância pertence, isto é,

$$\bar{D}_i = (\vec{x}_i, y_i) \quad (1)$$

na qual \vec{x}_i é um vetor que representa os atributos previsoires da instância \bar{D}_i , e y_i é o valor da classe associada a essa instância.

Trata-se uma instância como sendo um par $(\vec{x}_i, f(\vec{x}_i))$, onde \vec{x}_i é a entrada e $f(\vec{x}_i)$ é a saída da função aplicada a \vec{x}_i . Portanto, o sistema de aprendizagem deve construir um modelo $y = f(\vec{x}_i)$, de uma função desconhecida f , também chamada de função conceito, que permite prever valores y para instâncias previamente não vistas. Entretanto, em alguns casos o número de instâncias durante a criação do modelo pode não ser suficiente para caracterizar completamente essa função f . Dado um conjunto de dados para treinamento, a tarefa dos sistemas de aprendizagem é de induzir uma função h que aproxima f , ou seja, $h(\vec{x}_i) \approx f(\vec{x}_i)$. Nesse caso, h é chamada de hipótese sobre a função conceito f .

3.2 TÉCNICAS DE APRENDIZAGEM DE MÁQUINA

Nesta seção serão apresentadas as técnicas de aprendizagem de máquina que serão utilizadas para classificação dos dados de mastigação de ruminantes.

3.2.1 REDES NEURAIS ARTIFICIAIS

Uma rede neural artificial (RNA) é um sistema de aprendizagem conexionista desenvolvido de maneira a simular a estrutura de funcionamento do cérebro humano. Geralmente, a RNA é implementada por meio de componentes eletrônicos ou é simulada em programação em um computador digital (HAYKIN, 2001).

As pesquisas relacionadas à RNAs tiveram como base o trabalho realizado por McCulloch e Pitts (1943), no qual foram apresentados procedimentos matemáticos que representavam o funcionamento dos neurônios biológicos. Nesse modelo, os neurônios artificiais propostos eram capazes de executar funções lógicas simples e cada neurônio era capaz de executar uma função diferente. Esse trabalho não apresentou aplicações práticas, nem um sistema computacional com capacidade de aprender, mas serviu como base conceitual para os estudos relacionados a RNAs.

Outra pesquisa que contribuiu no desenvolvimento das RNAs foi o trabalho realizado por Hebb (1949), que apresentou um modelo de aprendizagem com base em regras de

modificação de pesos. Seu trabalho propôs que a medida que o organismo humano aprende tarefas funcionais diferentes, a conectividade do cérebro é modificada e agrupamentos neurais são criados por meio dessas modificações.

Rochester et al. (1956) abordaram o uso do modelo proposto por McCulloch e Pitts (1943) em conjunto com as regras de aprendizagem propostas por (HEBB, 1949) para o desenvolvimento de modelos computacionais para testar a teoria neural. No trabalho de Rosenblatt (1958) foi abordado o método *Perceptron*, que trabalhava com aprendizagem supervisionada para o reconhecimento de padrões ópticos. Porém, até então, poucos avanços na aplicação prática de RNAs foram realizados.

Entre a década de 70 e início da década de 80 diminuiu-se o interesse por parte dos pesquisadores em RNA, principalmente pela falta de computadores pessoais ou estações de trabalho para experimentação e falta de incentivos financeiros para as pesquisas (COWAN, 1990). Nos anos 80, o interesse pela área retornou, devido, em grande parte, ao surgimento de novos modelos de RNAs (HOPFIELD, 1982; KOHONEN, 1982).

Mas foi no trabalho realizado por Rumelhart e McClelland (1986) que foram alcançados significativos avanços na área de RNA. Neste foi proposto o algoritmo para o treinamento de RNAs chamado de retropropagação (*back-propagation*), e foi descrita sua aplicação no processo de aprendizagem de máquina. Em seu trabalho foi demonstrado como implementar esse algoritmo em sistemas computacionais, o que, aliado ao surgimento de computadores com maior poder de processamento, permitiu a implementação das RNAs, possibilitando avanços na área de inteligência artificial.

3.2.1.1 CONCEITOS FUNDAMENTAIS

Para entender a forma de funcionamento dos neurônios e RNAs é importante conhecer o funcionamento sistema nervoso humano. Esse sistema é responsável pela forma com que ocorre a tomada de decisões e pela maneira como organismo se adapta ao meio ambiente. No sistema nervoso humano essa função ocorre por meio de aprendizagem contínua. Tal sistema é composto por células responsáveis pelo seu funcionamento, que são os neurônios (HAYKIN, 2001).

Os principais componentes de um neurônio natural são: dendritos, soma (corpo celular) e axônio. Os dendritos são responsáveis pela recepção de estímulos nervosos vindos de outros neurônios ou do ambiente. Esses estímulos são transmitidos para o soma. O soma é responsável pela coleta das informações vindas dos dendritos e seu processamento. Com base

na intensidade e frequência dos estímulos recebidos, o soma gera um novo impulso elétrico que é então enviado para o axônio. O axônio é um prolongamento do neurônio, que conduz os impulsos elétricos até outros neurônios. Os sinais do neurônio fluem dos dendritos para o corpo celular e em seguida para o axônio. A ligação entre um axônio e o dendrito de outro neurônio é chamado de sinapse. As sinapses são as unidades que tratam as interações entre os neurônios (HAYKIN, 2001). A Figura 6 exibe a estrutura de um neurônio natural.

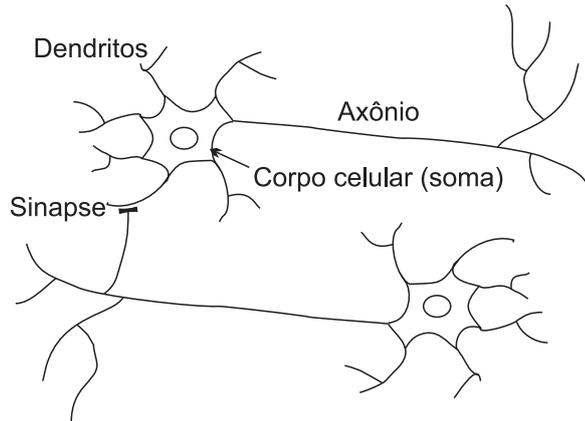


Figura 6: Neurônio natural.

Fonte: Adaptado de Haykin (2001).

3.2.1.2 NEURÔNIOS ARTIFICIAIS

As RNAs são formadas por neurônios artificiais que também são denominados de nós ou elementos processadores. O neurônio artificial tem base na abordagem proposta por McCulloch e Pitts (1943), e tem similaridade com o funcionamento de um neurônio natural. Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural (HAYKIN, 2001). O diagrama de blocos da Figura 7 mostra o modelo de um neurônio artificial.

A estrutura do neurônio artificial exibido na Figura 7 possui m terminais de entrada x_1, x_2, \dots, x_m (que representam os dendritos) com pesos associados $w_{k1}, w_{k2}, \dots, w_{km}$ para cada entrada. Os pesos permitem emular o comportamento das sinapses. Por exemplo, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso w_{kj} , onde k se refere ao neurônio e j se refere ao terminal de entrada da sinapse à qual o peso se refere. O peso sináptico de um neurônio artificial pode possuir tanto sinais excitatórios (positivos) quanto sinais inibitórios (negativos). O próximo bloco do diagrama mostrado na Figura 7 é um somador (combinador linear), o qual soma os sinais de entrada, ponderados pelas respectivas sinapses do neurônio. Outro bloco do diagrama da Figura 7 é a função de ativação que restringe

a amplitude da saída de um neurônio. Os valores normalizados da amplitude de saída de um neurônio pertencem ao intervalo $[0,1]$ ou $[-1,1]$. Outro elemento presente no modelo é o *bias*, representado por b_k , sua aplicação é externa e pode aumentar ou diminuir a entrada da função de ativação.

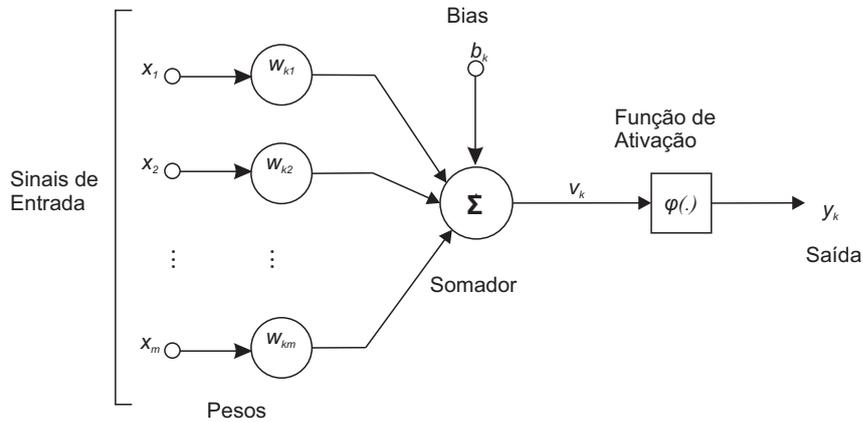


Figura 7: Modelo de um neurônio artificial.

Fonte: Adaptado de Haykin (2001).

Um neurônio k pode ser descrito por (HAYKIN, 2001)

$$y_k = \varphi(v_k + b_k), \quad (2)$$

onde

$$v_k = \sum_{j=1}^m w_{kj}x_j, \quad (3)$$

onde x_1, x_2, \dots, x_m é o vetor de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; v_k é a saída do combinador linear; b_k é o *bias*; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio k .

3.2.1.3 ARQUITETURAS DE REDE: REDES NEURAIS DE MÚLTIPLAS CAMADAS (MLP)

Estudar a arquitetura de uma rede neural artificial é importante, pois o seu arranjo depende do problema que irá ser tratado pela rede. O algoritmo de aprendizagem a ser aplicado durante o treinamento da rede também depende de sua arquitetura, ou seja, a maneira com que seus neurônios estão estruturados. Para a escolha de uma estrutura de RNA são analisados o número de camadas, número de neurônios (nós computacionais) por camada, tipo de conexões

entre os neurônios e a topologia da rede (HAYKIN, 2001).

As redes de múltiplas camadas alimentadas diretamente (*feedforward*) possuem fluxo de informação unidirecional. Essas redes neurais são também chamadas de *perceptrons* de múltiplas camadas (MLP, *multilayer perceptron*). Nessa arquitetura, as RNAs possuem uma camada de entrada, uma ou mais camadas ocultas (camada(s) intermediária(s)) e uma camada de saída, como mostrado na Figura 8. A camada de entrada da rede é formada pelos elementos do padrão de ativação (vetor de dados de entrada). Os elementos desse vetor serão aplicados aos nós computacionais (neurônios) da segunda camada da rede (primeira camada oculta). As saídas da segunda camada serão adotadas como entradas para a terceira e, assim por diante, até o final da rede. O conjunto de dados de saída dos neurônios da camada final constitui a resposta global da RNA para o vetor de entrada fornecido pelos nós da primeira camada (HAYKIN, 2001).

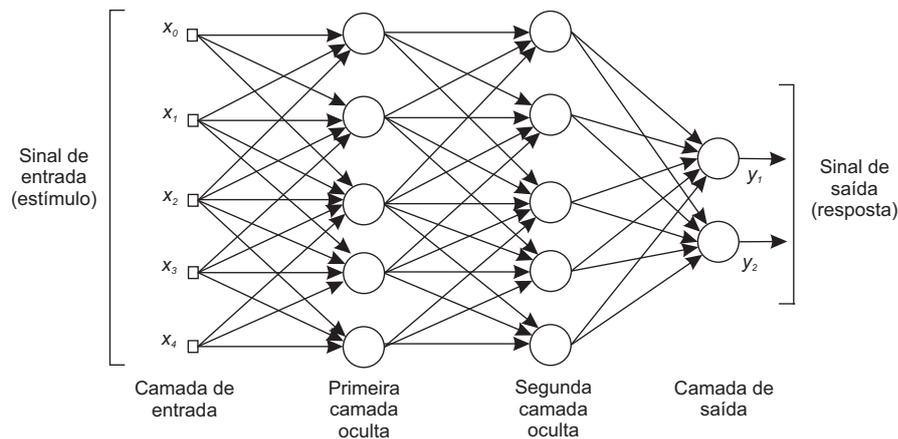


Figura 8: Arquitetura de uma rede MLP com duas camadas ocultas.

Fonte: Adaptado de Haykin (2001).

O modelo de rede MLP presente na Figura 8 possui quatro entradas x_1 , x_2 , x_3 , e x_4 e um *bias* (x_0), duas saídas y_1 e y_2 , e cinco neurônios em cada camada oculta. O número de nós na camada de entrada e saída está relacionado à dimensão dos dados de entrada e saída, e o número de neurônios e de camadas intermediárias depende da complexidade do problema. Problemas mais complexos podem exigir um maior número de neurônios, entretanto o número excessivo de neurônios na camada intermediária pode gerar resultados indesejáveis, como a possibilidade da rede perder a capacidade de generalização (HAYKIN, 2001).

Na Figura 9 é apresentado o modelo de um *perceptron* que é a unidade básica da MLP. Esse modelo possui o *bias*, duas entradas e uma única saída. Assim, a saída do *perceptron* é dada em função da combinação linear das entradas com seus respectivos pesos adicionado do *bias*. Com base em (2) e (3) é calculada a saída do *perceptron*. Assim,

$$v_k = \left(\sum_{j=1}^m (x_j w_j) \right), \quad (4)$$

na qual, v_k é o resultado da combinação linear das entradas e pesos no neurônio k , x_j é a m -ésima entrada de um total de m entradas e w_m é o peso associada à m -ésima entrada. O peso w_0 é na verdade o *bias* que é adicionado a combinação linear, portanto x_0 é uma constante com valor de 1 (ou -1), ao invés de ser uma entrada.

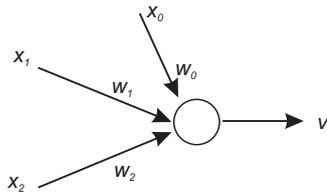


Figura 9: Modelo de um perceptron

Fonte: Adaptado de Haykin (2001)

A saída do neurônio k é dada por

$$y_k = \varphi(v_k), \quad (5)$$

onde $\varphi(\cdot)$ é a função de ativação, que irá definir a saída y_k do perceptron k .

Existem diversas funções que podem ser usadas como função de ativação, como a função de limiar, a função linear por partes, a função sigmoide, a tangente hiperbólica sigmoideal, entre outras. No caso específico da MLP treinada com o algoritmo *back-propagation*, é utilizada uma função que seja diferenciável em todos os pontos, sendo muito comum o uso da função sigmoide e tangente hiperbólica sigmoideal (HAYKIN, 2001). A função sigmoide, mostrada na Figura 10, é descrita por

$$\varphi(v) = \frac{1}{1 + \exp^{-v_k}}. \quad (6)$$

A função tangente hiperbólica sigmoideal é descrita em (7), e mostrada na Figura 11 (HAYKIN, 2001),

$$\varphi(v) = \tanh(v_k) = \frac{1 - \exp^{-v_k}}{1 + \exp^{-v_k}}. \quad (7)$$

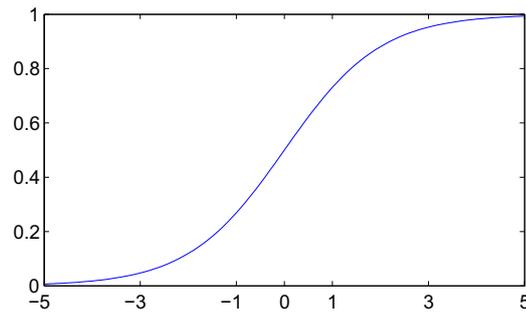


Figura 10: Função sigmoide.

Fonte: Desenvolvido pelo autor.

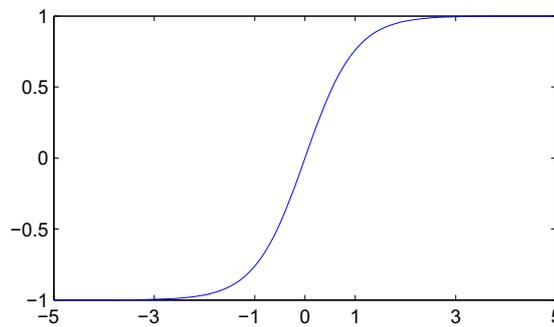


Figura 11: Função tangente hiperbólica sigmoideal.

Fonte: Desenvolvido pelo autor.

3.2.1.4 ALGORITMO *BACK-PROPAGATION*

Uma das principais propriedades das RNAs é sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem. Haykin (2001) define a aprendizagem de uma RNA como:

Aprendizagem é um processo pelo qual parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 2001, p.75).

Vários algoritmos têm sido propostos na literatura para o ajuste dos parâmetros de uma RNA. Por ajuste de parâmetros entende-se, principalmente, a definição dos valores dos pesos associados às conexões da rede que fazem com que o modelo obtenha melhor desempenho, geralmente medido pela capacidade que a rede possui de classificar corretamente a classe de uma nova instância. Esses algoritmos, referenciados como de treinamento, são formados por um conjunto de regras bem definidas que especificam quando e como deve ser alterado o valor de cada peso. Diversos autores propuseram algoritmos de treinamento para RNAs seguindo os paradigmas de aprendizagem supervisionada, não supervisionada e por reforço.

Esses algoritmos podem ser divididos de acordo com cinco regras básicas de aprendizagem (HAYKIN, 2001):

- Aprendizagem por correção de erro: geralmente utilizada em aprendizagem supervisionada. Procura ajustar os pesos da RNA de forma a reduzir os erros cometidos pela rede;
- Aprendizagem baseada em memória: opera memorizando explicitamente os dados de treinamento;
- Aprendizagem hebbiana: frequentemente usada em aprendizagem não supervisionada. É baseada na regra de Hebb, que diz que, se dois neurônios estão simultaneamente ativos, a conexão entre eles deve ser reforçada;
- Aprendizagem competitiva: adotada na aprendizagem não supervisionada. Promove uma competição entre neurônios para definir qual ou quais devem ter seus pesos ajustados. Os neurônios que vencem a competição geral são os que respondem mais fortemente ao objeto fornecido aos seus terminais de entrada;
- Aprendizagem de Boltzmann: algoritmos estocásticos baseados em princípios observados na mecânica estatística.

No estudo realizado nesse trabalho é empregada aprendizagem supervisionada por meio do algoritmo *back-propagation* proposto por Rumelhart e McClelland (1986). Esse algoritmo utiliza a regra de aprendizagem por correção do erro.

O *back-propagation* é o principal algoritmo para treinamentos de RNA em aprendizagem supervisionada (HAYKIN, 2001). Esse algoritmo é constituído da iteração de duas fases: uma para frente chamada de *foward* (propagação); e outra para trás denominada *backward* (retropropagação). Na fase *foward*, cada instância de entrada é apresentada à rede. A instância é, primeiramente, recebida por cada um dos neurônios da primeira camada intermediária da rede, quando é ponderado pelo peso associado a suas conexões de entrada correspondentes. Cada neurônio nessa camada aplica a função de ativação a sua entrada total e produz um valor de saída, que serve como valor de entrada para os neurônios da camada seguinte. Esse processo continua até que os neurônios da camada de saída produzam cada um seu valor de saída, o qual é comparado ao valor desejado para a saída desse neurônio. A diferença entre os valores de saída produzidos e desejados para cada neurônio da camada de saída indica o erro cometido pela rede para o objeto apresentado. O valor do erro de cada

neurônio da camada de saída é então utilizado na fase *backward* para ajustar seus pesos de entrada. O ajuste prossegue da camada de saída até a primeira camada intermediária (HAYKIN, 2001).

O algoritmo *back-propagation* funciona, basicamente, apresentando diversas vezes cada instância do conjunto de treinamento até que uma condição de parada seja satisfeita. Em cada instância apresentada, os pesos dos perceptrons são alterados de forma a diminuir o erro obtido na saída da rede, que é dado em função da saída esperada para a instância apresentada, e da saída obtida pela rede. Dessa maneira, o algoritmo pode ser organizado nos seguintes passos (RUSSEL; NORVIG, 2004):

- Apresentar uma instância de treinamento à rede;
- Determinar a saída da rede para a instância apresentada;
- Calcular o erro na saída da rede;
- Atualizar os pesos dos perceptrons da camada de saída para diminuir o erro;
- Retropropagar o erro para as camadas anteriores;
- Ajustar os pesos dos perceptrons das demais camadas;
- Repetir os passos anteriores até que um critério de parada seja satisfeito.

Para descrever o funcionamento do algoritmo *back-propagation*, será considerada uma RNA em que os índices i , j e k referem-se a neurônios diferentes na rede, onde i se refere ao neurônio da camada anterior à camada j ; j é neurônio da camada j ; e k é neurônio da camada posterior à camada j , e n representa a n -ésima iteração, ou seja, quando a n -ésima instância é apresentada à rede. Como o algoritmo *back-propagation* realiza a retropropagação do erro, calcula-se o erro na saída do neurônio j na iteração n por meio de (HAYKIN, 2001)

$$e_j(n) = d_j(n) - y_j(n), \quad (8)$$

no qual $e_j(n)$ corresponde ao erro na saída do neurônio j na iteração n ; $d_j(n)$ corresponde à resposta desejada para o neurônio j e é utilizado para computar o valor de $e_j(n)$ e $y_j(n)$ corresponde ao sinal do padrão apresentado na saída do neurônio j na interação n .

Haykin (2001) define o valor instantâneo do erro para o neurônio j como sendo $0.5e_j^2(n)$. Assim, o valor instantâneo total do erro $\varepsilon(n)$ é obtido na soma do valor instantâneo do erro sobre todos os neurônios da camada de saída, como descrito em

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n), \quad (9)$$

onde $\varepsilon(n)$ refere-se ao erro quadrático ou erro total e C é o conjunto formado por todos os neurônios da camada de saída da rede.

Adotando m como o número total de instâncias (exemplos) contidos no conjunto de treinamento, o valor médio do erro quadrático (ε_{med}) é obtido somando-se $\varepsilon(n) \forall n$ e normalizando-o em relação ao tamanho m do conjunto de treinamento, pode ser escrito como (HAYKIN, 2001)

$$\varepsilon_{med} = \frac{1}{m} \sum_{n=1}^m \varepsilon(n), \quad (10)$$

sendo que ε_{med} representa uma função custo como medida de desempenho da aprendizagem e, portanto, o objetivo da aprendizagem é minimizar o valor de ε_{med} . A correção dos pesos das ligações entre os neurônios (sinapses) é feita para todas as instâncias até que um ciclo (uma completa apresentação de todas as instâncias) tenha sido atingido. Este ciclo é denominado época. Os ajustes das sinapses são feitos de acordo com os respectivos erros computados para cada instância apresentada. As execuções das épocas são repetidas até que o erro médio total seja zero ou tenha atingido um valor mínimo, sendo o critério de parada para construção da RNA (HAYKIN, 2001).

Considerando a Figura 12, que simboliza o neurônio j sendo alimentado por um conjunto de sinais produzidos na camada anterior, o chamado campo local induzido $v_j(n)$, produzido na entrada da função de ativação $\varphi(\cdot)$ e associado ao neurônio j , é dado por (HAYKIN, 2001)

$$v_j = \sum_{i=0}^m (w_{ji}(n)y_i(n)), \quad (11)$$

onde m é o número total de entradas (excluindo o bias) aplicadas ao neurônio j . O peso w_{ji} corresponde à sinapse que conecta a saída do neurônio i à entrada do neurônio j na iteração n . O peso w_{j0} (correspondente à entrada fixa $y_0 = +1$) possui valor igual a b_j . Logo, a saída do neurônio j é dada por (HAYKIN, 2001)

$$y_j(n) = \varphi_j(v_j(n)). \quad (12)$$

Então, o algoritmo *back-propagation* aplica uma correção $\Delta w_{ji}(n)$ na sinapse w_{ji} , dado por (13). A regra de atualização dos pesos da rede baseia-se em uma regra conhecida como regra delta, chamada de regra delta generalizada e é dada por (WIDROW, 1962)

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n), \quad (13)$$

onde η é uma constante chamada de taxa de aprendizagem (geralmente com valores entre 0,2 e 0,8). O gradiente local $\delta_j(n)$ é definido como (HAYKIN, 2001)

$$\delta_j(n) = e_j(n) \phi_j'(v_j(n)). \quad (14)$$

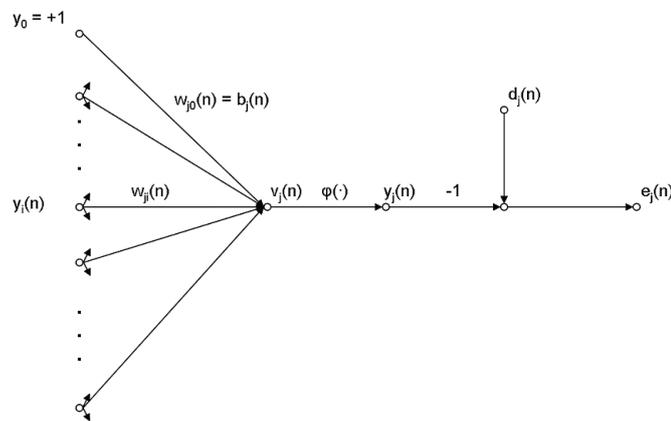


Figura 12: Fluxo do sinal do neurônio de saída j .

Fonte: Adaptado de Haykin (2001).

O gradiente local aponta para as modificações necessárias nos pesos sinápticos, ou seja, a direção onde o erro deverá diminuir.

Com base em (13) e (14), em que $\Delta w_{ji}(n)$ e $e_j(n)$ são baseados na saída do neurônio j , podem ser gerados dois casos distintos. No primeiro caso o neurônio j está na camada de saída. Nesse caso aplica-se (8) para o calcular o sinal de erro $e_j(n)$, então calcula-se o gradiente local $\delta_j(n)$ empregando (14). No segundo caso, o neurônio j é um neurônio de uma camada oculta.

Para o caso em que o neurônio j é da camada oculta, o gradiente local deve ser redefinido da seguinte forma (HAYKIN, 2001)

$$\delta_j(n) = \frac{\partial \varepsilon(n)}{\partial y_j(n)} \phi_j'(v_j(n)). \quad (15)$$

Reajustando (9) para o neurônio k , tem-se

$$\varepsilon(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n). \quad (16)$$

O erro $e_k(n)$ para o neurônio k é dado por (HAYKIN, 2001)

$$e_k(n) = d_k(n) - \varphi(v_k(n)). \quad (17)$$

Com base na Figura 13, é definido que para o neurônio k o campo de indução local $v_k(n)$ é dado por (HAYKIN, 2001)

$$v_k = \sum_{i=0}^N (w_{ki}(n)y_i(n)), \quad (18)$$

onde N é o total de entradas (excluindo o bias) do neurônio k .

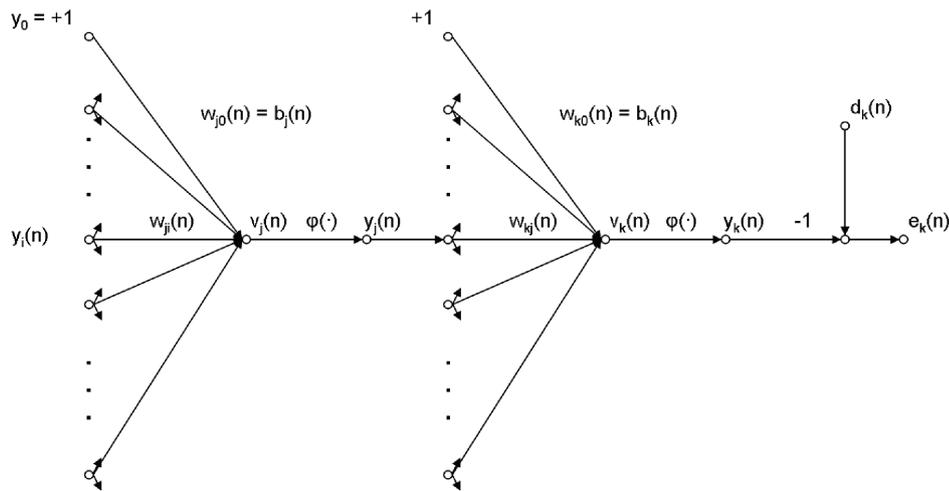


Figura 13: Fluxo do sinal do neurônio de saída k conectado ao neurônio oculto j .

Fonte: Adaptado de Haykin (2001).

Então é obtida a equação do algoritmo *back-propagation* para o gradiente local $\delta_k(n)$, representada por

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_{k \in C} \delta_k(n) w_{kj}(n). \quad (19)$$

Durante o treinamento da rede pode ser necessário o ajuste de parâmetros visando amenizar possíveis problemas durante o treinamento, por exemplo, no cálculo da regra delta generalizada 13, é adotada a constante η , que representa a taxa de aprendizagem. O valor da

taxa de aprendizagem η pode ter uma forte influência no tempo necessário à convergência da rede. Podendo ser necessário um número grande de épocas (ciclos) para que um bom modelo seja induzido. Neste contexto, a introdução do termo *momentum* α , pode influenciar positivamente na solução desse problema (RUMELHART; MCCLELLAND, 1986). O termo quantifica o grau de importância da variação de peso do ciclo anterior ao ciclo atual, sendo definido por

$$\Delta w_{ji}(n+1) = w_{ji}(n) + \eta \delta_j(n) y_i(n) + \alpha (w_{ji}(n) - w_{ji}(n-1)). \quad (20)$$

O Algoritmo 1 descreve os passos seguidos pelo algoritmo *back-propagation* no treinamento de uma RNA multicamadas.

A seguir, citamos, dentre muitos, apenas alguns trabalhos que utilizaram RNAs em dados oriundos de sensores FBG.

No estudo experimental realizado por Luo et al. (2010), foi proposta uma técnica para o reconhecimento de danos estruturais por meio de sensores FBG e RNA. Quatro sensores FBG foram fixados em uma placa metálica a fim de medir as deformações ocorridas durante as aplicações de cargas na placa. A RNA foi treinada com o algoritmo *back-propagation*. O classificador foi capaz de reconhecer corretamente os casos em que a placa sofreu deformações durante as cargas, mesmo quando aplicadas em vários pontos sobre uma estrutura.

No trabalho realizado por Mieloszyk et al. (2011), RNAs são utilizadas para classificação de dados relacionados ao monitoramento de integridade estrutural em asas de aeronaves, por meio de dados coletados de sensores FBG. Os valores relacionados as deformações ocorridas no sensor durante as simulações formaram o conjunto de treinamento. Os resultados mostraram que o classificador gerado obteve 100% de acerto na identificação do local dos danos estruturais nas asas.

RNAs foram empregadas por Panopoulou et al. (2013) na classificação de dados de sensores aplicados na verificação da integridade de estruturas aeroespaciais. O conjunto de treinamento da RNA foi formado por meio dos dados relacionados à deformação dos sensores FBG. A eficiência de classificação para a identificação danos atingiu 91,00% de acerto.

Li et al. (2014) utilizaram sensores FBG e RNA para o diagnóstico de cabos rompidos em pontes suspensas. Nesse trabalho o algoritmo *back-propagation* foi empregado em um conjunto de treinamento composto por informações relacionadas a deformações no sensor, quando submetido a várias combinações de cargas aplicadas nos cabos de aço. A RNA foi capaz de reconhecer até 86,70% dos casos em que os cabos estavam rompidos.

É possível observar que diversos trabalhos beneficiaram-se do uso de RNAs para tarefas de classificação de dados, mostrando que o uso de RNAs pode ser promissor para o reconhecimento de padrões em dados adquiridos de sensores. Além disso, classificadores gerados com RNAs possuem boa velocidade de classificação, podendo ser empregados em problemas de classificação de padrões em tempo real (HAYKIN, 2001).

Algoritmo 1 Algoritmo de treinamento *back-propagation*

Entrada: Conjunto de treinamento

Saída: Rede MLP com valores dos pesos ajustados

início

Inicializar pesos da rede com valores aleatórios $w_{k1}, w_{k2}, \dots, w_{km}$

Inicializar $erro_{total} = 0$

Inicializar o erro mínimo estabelecido para rede E

Inicializar a taxa de aprendizado η

Inicializar o termo *momentum* α

repita

para cada instância x_i do conjunto de treinamento **faça**

para cada camada da rede, a partir da primeira camada intermediária **faça**

para cada neurônio j da camada atual **faça**

Calcular o valor da saída produzida pelo neurônio, equação (12)

fim

fim

Calcular $erro_{parcial}$ (equação (8))

para cada camada da rede, a partir da camada de saída **faça**

para cada neurônio j da camada atual **faça**

Ajustar pesos do neurônio (equação (20))

fim

fim

Calcular $erro_{total} = erro_{total} + erro_{parcial}$ (equação (9))

fim

até $erro_{total} < E$;

fim

3.2.2 ÁRVORES DE DECISÃO

Árvore de decisão é um método de aprendizagem de máquina simbólico aplicado na inferência indutiva. Uma árvore de decisão usa a estratégia dividir para conquistar para resolver um problema de decisão (QUINLAN, 1993). Nas árvores de decisão, um problema complexo é dividido em problemas mais simples. Nesses subproblemas é aplicada recursivamente a mesma estratégia. As soluções dos subproblemas podem ser combinadas na forma de uma árvore, para produzir a solução de um problema complexo (MITCHELL, 1997). Essa é a ideia básica por trás de algoritmos baseados em árvores de decisão, tais como ID3, ASSISTANT, CART, C4.5.

Uma árvore de decisão tem a estrutura formada por vértices (nós) que representam os atributos de uma instância, por arestas (ligações) provenientes desses vértices, que recebem os possíveis valores do atributo em questão e de vértices terminais (nós folha), que representam as diferentes classes presentes no conjunto de dados, como no exemplo exibido na Figura 14. A classificação consiste em seguir o caminho determinado pelos sucessivos vértices dispostos ao longo da árvore até ser alcançado um vértice terminal, que contém a classe a ser atribuída a respectiva instância.

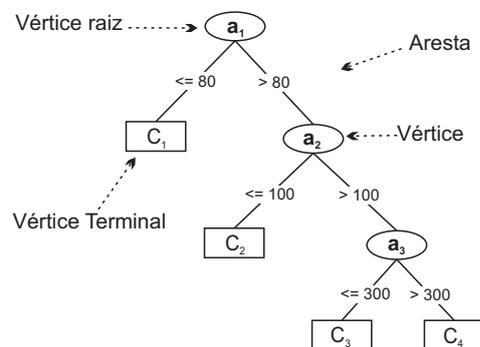


Figura 14: Exemplo de uma árvore de decisão.

Fonte: Autoria própria.

Na Figura 14, a estrutura da árvore de decisão se inicia no vértice raiz, representado pelo atributo a_1 que classifica valores menores ou iguais a 80 como sendo pertencentes à classe C_1 . O segundo vértice de decisão, representado pelo atributo a_2 que classifica valores menores ou iguais a 100 como sendo pertencentes à classe C_2 , e assim sucessivamente.

Na subseção 3.2.2.1 será abordado o algoritmo de árvore de decisão ID3, que serviu de base para o desenvolvimento do algoritmo C4.5 mostrado na subseção 3.2.2.2.

3.2.2.1 ALGORITMO ID3

O algoritmo de árvore de decisão ID3, proposto por Quinlan (1979), foi um dos primeiros algoritmos de árvore de decisão, tendo sua elaboração baseada em sistemas de inferência e em conceitos de sistemas de aprendizagem já existentes na época.

O ID3 foi desenvolvido visando à resolução de problemas que contenham atributos categóricos, ou seja, com números finitos de valores, por exemplo {verdadeiro, falso}, ou {sucesso, falha}. Este algoritmo necessita que os valores dos atributos não possuam ruídos. Sendo assim, estes valores devem ser tratados previamente no caso da existência de ruídos (QUINLAN, 1979).

Esse algoritmo adota o critério ganho de informação para a escolha da característica (atributo previsor) a ser atribuído a cada vértice de decisão da árvore. Para construção da árvore de decisão, o algoritmo ID3 utiliza um conjunto de treinamento com instâncias (exemplos), criando uma estrutura de decisão que pode ser aplicada na classificação de novas instâncias (QUINLAN, 1979).

3.2.2.2 ALGORITMO C4.5

O algoritmo C4.5 foi desenvolvido por Quinlan (1993) e trata-se de um aprimoramento do algoritmo ID3, sendo capaz de trabalhar com atributos categóricos e quantitativos. Neste algoritmo a escolha da melhor característica pode ser efetuada pelo critério ganho de informação ou pelo critério da razão do ganho de informação. Assim como no algoritmo ID3, o algoritmo C4.5 adota um conjunto de treinamento com instâncias para construção da árvore de decisão (QUINLAN, 1993).

A construção de árvores de decisão pode gerar estruturas de decisão de grandes dimensões, muitas vezes estruturas complexas e podendo comprometer o desempenho do algoritmo classificador. O processo de poda em árvores de decisão visa limitar as dimensões da árvore, removendo vértices de decisão que não contribuem para classificação da árvore. Dessa forma, obtêm-se uma árvore de menor complexidade, melhorando seu desempenho e sua compreensão. O algoritmo C4.5 pode aplicar o método de pós-poda proposto em (QUINLAN, 1987).

3.2.2.3 PROCESSO DE CONSTRUÇÃO DE ÁRVORES DE DECISÃO

Para a construção da árvore de decisão será considerado um conjunto de dados D com m instâncias, $D = \{\bar{D}_1, \bar{D}_2, \dots, \bar{D}_m\}$, onde cada instância \bar{D}_i , $i = 1, \dots, m$ é um conjunto com n atributos a_{ij} , onde $j = 1, 2, \dots, n$, isto é, $\bar{D}_i = \{a_{i1}, a_{i2}, \dots, a_{in}\}$. O conjunto dos possíveis valores para o atributo a_{ij} é representado por $dom(a_{ij}) = \{v_1, v_2, \dots, v_k\}$, onde v_l , $l = 1, \dots, k$, são os possíveis valores para o atributo a_{ij} . Cada instância do conjunto de dados D é classificada de acordo com um conjunto de classes $C = \{c_1, c_2, \dots, c_w\}$, onde w é o número de classes.

Os critérios de seleção de atributos servem para determinar quais atributos serão utilizados como vértices de decisão durante a construção do algoritmo classificador. O ganho de informação $G(D, a_{ij})$ é um critério de seleção de atributos utilizado pelos algoritmos ID3 e C4.5, sendo que este último adota também o cálculo da razão do ganho de informação $RG(D, a_{ij})$ para construir a estrutura do classificador (QUINLAN, 1979, 1993). Os atributos que geram a maior razão do ganho de informação são usados como vértices de decisão.

O ganho de informação tem como base uma medida conhecida como entropia $E(D)$ (QUINLAN, 1979, 1993). A entropia tem sua origem na teoria da informação, e mede a A Entropia mede a pureza de um conjunto de dados (GRAY, 1990). A entropia $E(D)$ para o conjunto de dados D é dada por (MITCHELL, 1997)

$$E(D) = \sum_{i=1}^w -p_i \log_2 p_i, \quad (21)$$

onde D é o conjunto de instâncias; w é o número de classes e p_i é a proporção de D que pertence à classe i , sendo

$$p_i = \frac{|D_i|}{|D|}, \quad (22)$$

onde $|D_i|$ é a cardinalidade do conjunto de instâncias classificadas na i -ésima partição; $|D|$ é a cardinalidade do conjunto de dados D .

O ganho de informação $G(D, a_{ij})$ permite medir a diminuição da entropia esperada ao utilizar o atributo a_{ij} para realizar a partição do conjunto de dados. O ganho de informação $G(D, a_{ij})$ resultante da adoção de uma partição baseada num dado atributo é dado por (QUINLAN, 1979)

$$G(D, a_{ij}) = E(D) - \sum_{l=1}^k \frac{|D_l|}{|D|} E(D_l), \quad (23)$$

onde $G(D, a_{ij})$ é o ganho do atributo a_{ij} sobre o conjunto de dados D ; D_l é o subconjunto de D no qual o atributo a_{ij} tem valor v_l , isto é, $D_l = \{\bar{D}_i \in D | a_{ij}(\bar{D}_i) = v_l\}$; $|D_l|$ é a cardinalidade do conjunto de instâncias resultantes do particionamento de D no qual o atributo a_{ij} tem valor v_l ; k é o número dos distintos valores do $dom(a_{ij})$.

Para atributos com grande quantidade de valores distintos, o ganho de informação possui como desvantagem a geração de árvores muito grandes. Para contornar esta situação, foi proposta uma alternativa baseada na razão do ganho de informação. O cálculo da razão do ganho de informação $RG(D, a_{ij})$ é realizado por meio do uso do ganho de informação e a informação do atributo (QUINLAN, 1986)

$$RG(D, a_{ij}) = \frac{G(D, a_{ij})}{INF(D, a_{ij})}. \quad (24)$$

A informação do atributo a_{ij} em relação ao conjunto de dados D é dada por

$$INF(D, a_{ij}) = - \sum_{j=1}^k \frac{|D_j|}{|D|} \log_2 \frac{|D_j|}{|D|} \quad (25)$$

onde $|D_j|$ é a cardinalidade do conjunto de instâncias resultantes do particionamento de D pelos k valores do atributo a_{ij} . O cálculo de razão do ganho de informação é utilizado no algoritmo C4.5 (QUINLAN, 1993).

Para exemplificar o cálculo do ganho de informação e razão do ganho de informação serão adotados os dados da Tabela 3, que exibem um conjunto de instâncias que descrevem exemplos de pessoas que receberam ou não um empréstimo de um banco. O conjunto de dados possui como atributos previsores o valor do empréstimo solicitado, a idade da pessoa solicitante, o seu salário e se ela possui ou não conta no banco. Na Tabela 4 estão os atributos previsores e seus possíveis valores. Na Tabela 3, o atributo empréstimo é considerado o atributo classe, os valores associados a esse atributo correspondem a situações já ocorridas, em que pessoas foram categorizadas como aptas ou não aptas a receber empréstimos. Portanto, as instâncias listadas na Tabela 3 podem ser classificadas de acordo com duas classes (sim e não).

Tendo como exemplo os dados presentes na Tabela 3, foram realizados os cálculos para obtenção da razão do ganho de informação. Os cálculos são descritos no Apêndice A. O valor da entropia do conjunto de dados foi de 0,940. Esse dado foi necessário para o cálculo do ganho

de informação. A Tabela 5 mostra os valores da entropia para cada um dos possíveis valores do atributo valor, esses dados também foram utilizados no cálculo do ganho de informação.

Tabela 3: Conjunto de instâncias de treinamento

instância	valor	idade	salário	conta	empréstimo (Classe)
1	médio	sênior	baixo	sim	não
2	médio	sênior	baixo	não	não
3	baixo	sênior	baixo	sim	sim
4	alto	média	baixo	sim	sim
5	alto	jovem	alto	sim	sim
6	alto	jovem	alto	não	não
7	baixo	jovem	alto	não	sim
8	médio	média	baixo	sim	não
9	médio	jovem	alto	sim	sim
10	alto	média	alto	sim	sim
11	médio	média	alto	não	sim
12	baixo	media	baixo	não	sim
13	baixo	sênior	alto	sim	sim
14	alto	média	baixo	não	não

Fonte: Adaptado de Russel e Norvig (2004).

Tabela 4: Atributos previsores

Atributo	Valores
valor	baixo, médio, alto
idade	jovem, média, sênior
salário	baixo, alto
conta	sim, não

Tabela 5: Entropia para os valores do atributo valor (a_1).

Valor do Atributo	Entropia
a_1 - Baixo	0
a_1 - Médio	0,971
a_1 - Alto	0,971

A Tabela 6 mostra os valores obtidos após o cálculo do ganho de informação, informação e razão do ganho de informação dos atributos do conjunto D . O atributo que obteve o maior ganho de informação foi o atributo valor, o qual obteve 0.246, esse atributo seria designado como vértice raiz, no caso do algoritmo ID3.

Assim como para o ganho de informação, o atributo que obteve a maior razão de ganho de informação foi o atributo valor, o qual obteve 0.156, sendo designado como vértice raiz, no

caso do algoritmo C4.5. Após a definição do atributo raiz o cálculo deve ser feito recursivamente para os demais atributos. A Figura 15 ilustra a árvore de decisão gerada para o conjunto de treinamento apresentado na Tabela 3.

Tabela 6: Resumo do cálculo do ganho de informação, informação e razão do ganho de informação, para os atributos valor, idade, salário e conta.

Atributo	Ganho de Informação	Informação	Razão do Ganho de Informação
Valor (a_1)	0,246	1,577	0,156
Idade (a_2)	0,049	1,577	0,029
Salário (a_3)	0,151	1	0,151
Conta (a_4)	0,047	0,985	0,047

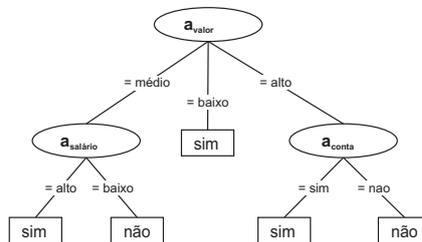


Figura 15: Árvore de decisão para o conjunto de treinamento da Tabela 3.

Fonte: Autoria própria.

O Algoritmo 2 descreve os passos seguidos pelo algoritmo de treinamento de árvore de decisão C4.5.

A seguir, citamos, dentre muitos, apenas alguns trabalhos que utilizaram árvores de decisão em dados oriundos de diferentes tipos de sensores.

Robert et al. (2009) utilizaram árvores de decisão para classificar padrões de comportamento em bovinos, os quais foram analisados por meio de sensores de movimento. Durante a etapa de formação do conjunto de treinamento foram selecionadas características relacionadas aos movimentos capturados pelos sensores, posicionados nos membros inferiores do animal sob estudo. O conjunto de regras gerado foi capaz de classificar corretamente 99,2% do tempo em que o animal estava em repouso e 98,00% do tempo que o animal estava em pé.

Kamphuis et al. (2010) induziram regras com o algoritmo C4.5 para o diagnóstico de doenças nas mamas de vacas leiteiras. O conjunto de treinamento foi formado com dados de sensores presentes em um equipamento de ordenha mecânica. Nesse estudo, 64% dos casos severos da doença foram corretamente identificados.

Sensores óticos e árvores de decisão foram empregados no diagnóstico de doenças causadas por bactérias em árvores produtoras de frutas cítricas (MISHRA et al., 2011). O

conjunto de treinamento foi formado por dados de quatro sensores óticos, os quais foram utilizados para avaliar as folhas de plantas saudáveis e com a presença de bactérias. O classificador gerado obteve taxa de acerto superior a 95%.

Algoritmo 2 Algoritmo de treinamento C4.5

Entrada: Conjunto de treinamento D

Saída: Árvore de Decisão

início

se *todas as instâncias de D pertencem a mesma classe* **então**

 retornar um único nó;

fim

senão

para cada atributo a_j *das instâncias do conjunto de treinamento D*

faça

 Calcular o valor da razão do ganho de informação;

 Escolher o atributo a_j com o maior valor da razão do ganho de informação;

 Cria nó de decisão na árvore;

para cada *partição das instâncias segundo os valores de a_j* **faça**

 Voltar ao Início;

fim

fim

fim

fim

No trabalho realizado por Diosdado et al. (2015), árvores de decisão foram empregadas na classificação de dados de sensores de movimento. Os dados dos sensores são utilizados para fornecer informações para locomoção de um exoesqueleto. Durante a etapa de formação do conjunto de treinamento, foram coletados dados de sensores posicionados nas articulações do exoesqueleto, o qual estava sendo controlado por um ser humano. O método abordado foi capaz de prever corretamente os movimentos realizados pelo ser humano e aplicá-los nos atuadores para a correta movimentação do exoesqueleto.

Diversos trabalhos beneficiaram-se do uso de árvores de decisão para tarefas de classificação de dados. Os classificadores gerados a partir de árvores de decisão possuem uma boa combinação entre taxa de acerto e velocidade de classificação (LIM et al., 2000). Estas características tornam as árvores de decisão uma escolha natural para o problema em questão e têm sido empregadas com êxito em diferentes áreas onde se faz necessária a classificação de

padrões.

3.3 CONSIDERAÇÕES FINAIS

Neste capítulo foram abordados os conceitos básicos de aprendizagem de máquina indutiva. Inicialmente, foram apresentados os conceitos sobre aprendizagem supervisionada, no qual as hipóteses são induzidas a partir de um conjunto de treinamento com instâncias rotuladas. Após os conceitos de aprendizagem de máquina foram abordados algoritmos de RNA e árvore de decisão. O algoritmo de RNA baseia-se no paradigma conexionista que é inspirado nas conexões neurais do sistema nervoso humano. O algoritmo de RNA é capaz de trabalhar com atributos que possuem valores contínuos e apresenta boa velocidade de treinamento e classificação. Entretanto, os pesos gerados após o treinamento da RNA não permitem uma análise clara dos principais atributos previsores do conjunto de dados. Então, foi estudado o algoritmo de árvore de decisão C4.5, o qual tem como base o paradigma simbólico. Os classificadores gerados com os algoritmos do paradigma simbólico permitem a visualização dos principais atributos previsores utilizados na formação do conjunto de regras, o que pode auxiliar durante a etapa de seleção de atributos previsores para geração dos conjuntos de treinamento. O algoritmo C4.5 é capaz de trabalhar com atributos compostos por valores contínuos, categóricos ou ausentes.

Dentre as técnicas escolhidas, o uso de RNAs pode ser útil quando há necessidade de velocidade na classificação em tempo real, enquanto que a técnica de árvore de decisão possui melhor velocidade de treinamento e permite visualizar por meio do conjunto de regras gerado os principais atributos previsores do conjunto de dados. Para o treinamento dos algoritmos de RNA e árvore de decisão, no Capítulo 4, são descritas as etapas de aquisição, pré-processamento dos dados e preparação dos conjuntos de treinamento. Os resultados obtidos por meio do treinamento desses algoritmos serão abordados no Capítulo 5.

4 METODOLOGIA

Neste capítulo são descritas as etapas de aquisição dos dados, pré-processamento e uso dos algoritmos de aprendizagem de máquina para gerar os classificadores. Inicialmente, será mostrada a aquisição e o pré-processamento dos dados obtidos nos ensaios *in vitro*, na qual foi utilizado um crânio cadavérico de caprino para a implantação do sensor FBG. Com este crânio simulou-se movimentos mastigatórios, os quais foram realizados com diferentes materiais entre a arcada dentária, a fim de simular as plantas forrageiras utilizadas no processo de ingestão de alimentos. Na sequência, são apresentadas as etapas de aquisição e pré-processamento dos dados nos ensaios *in vivo*, no qual foi utilizado um bovino da espécie *Bos taurus* para a implantação do sensor FBG e coleta de dados. Nesse ensaio, também foram fornecidos diferentes alimentos a espécie, com o objetivo de identificar o alimento que estava sendo consumindo, e foi acompanhado o processo de ruminação do animal.

4.1 AQUISIÇÃO DOS DADOS *In vitro*

Para aquisição dos dados nos ensaios *in vitro* foi empregada a abordagem proposta por Wosniack et al. (2012). Os ensaios realizados envolveram a coleta de dados correspondentes à cinco classes, sendo utilizadas para rotular os movimentos de mastigação de acordo com o tipo de material utilizado durante as simulações. Essas classes pertencem ao conjunto $C_{in vitro}$

$$C_{in vitro} = \{aveia, feno, ausência_material, plasticina_A, plasticina_B\}. \quad (26)$$

Inicialmente, foram coletados dados para a classe *ausência_material*, simulando a mastigação sem materiais na arcada dentária. Também realizou-se o mesmo movimento com a presença de *aveia* (*Avena sativa*), *feno* de Tifton (*Cynodon*) e duas plasticinas de texturas diferentes. A primeira plasticina possuía uma textura maleável e elástica composta, basicamente, por pasta de goma e água, aqui denominada de *plasticina_A*; a segunda possuía textura esponjosa e resistente, composta por espuma polimérica, denominada de *plasticina_B*.

As diferenças texturais adotadas para as plasticinas tiveram como objetivo a simulação das diferentes características inerentes às espécies forrageiras, as quais afetam o padrão do processo mastigatório animal. Com a *aveia* procurou-se fazer as simulações mastigatórias com a pastagem recém colhida, procurando manter as mesmas condições com as quais o alimento é fornecido para os animais. Com o *feno* foi utilizada a pastagem desidratada que é composta por um percentual menor de água e, conseqüentemente, oferece maior resistência à mastigação.

A Figura 16 ilustra as etapas envolvidas no processo de aquisição dos dados. Na primeira etapa, mostrada na Figura 16 (a), foi realizada a aplicação do sensor, na qual um sensor FBG, com comprimento de onda de 1545nm, foi fixado na mandíbula cadavérica de um caprino. O posicionamento do sensor FBG pode ser observado na Figura 17.

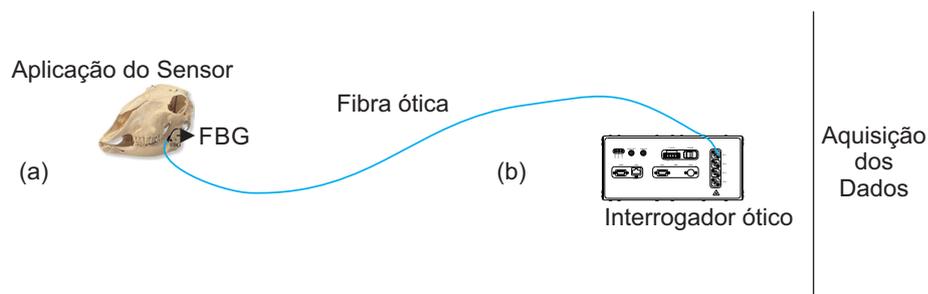


Figura 16: Ilustração da etapa de aquisição dos dados. (a) Aplicação do sensor, (b) aquisição dos dados.

Fonte: Autoria própria.

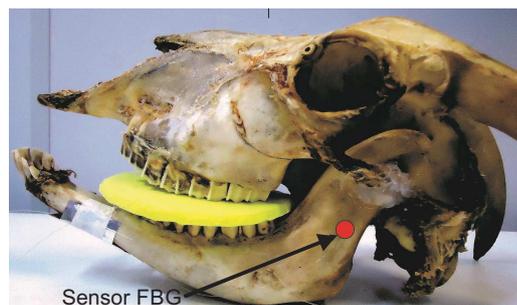


Figura 17: Crânio cadavérico de caprino utilizada nas simulações de mastigação.

Fonte: Wosniack et al. (2012).

Na Figura 16 (b), representando a segunda etapa, o sensor foi conectado a um interrogador óptico por meio de um cabo óptico. Então, o interrogador foi interligado por meio de uma interface de rede a um microcomputador responsável pela aquisição dos dados. Nos ensaios utilizou-se o interrogador DI410 e o programa CatmanEasy[®] para a aquisição dos sinais (HBM, 2014). A taxa de amostragem nos ensaios foi de 1000 amostras por segundo. Nessa

etapa, os movimentos mastigatórios para cada um dos materiais foram simulados manualmente. Inicialmente, os dados coletados foram armazenados em cinco arquivos de texto, sendo um arquivo para cada material, contendo uma coluna com o comprimento de onda e outra com o tempo. Para cada material foram coletados 80 segundos de mastigação, totalizando 400 segundos.

4.1.1 GERAÇÃO DOS CONJUNTOS DE TREINAMENTO

A Figura 18 ilustra as etapas de pré-processamento e classificação dos dados. Na etapa de pré-processamento, mostrada na Figura 18 (a), os arquivos com os dados coletados foram organizados em um único conjunto de dados e rotulados de acordo com o tipo de material utilizado durante as simulações. Ainda, nesta etapa, foram criados os conjuntos de treinamento.

A Figura 18 (b) representa a etapa final. Os dados resultantes do pré-processamento formaram os conjuntos de treinamento para a geração dos classificadores. Para o treinamento dos classificadores foram utilizadas as duas técnicas de aprendizagem de máquina abordadas no Capítulo 3 (RNA e árvore de decisão). A subseção 4.3 descreve a metodologia empregada na criação dos classificadores.

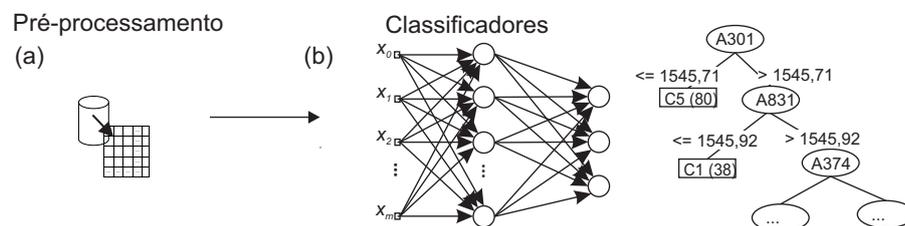


Figura 18: Ilustração das etapas de pré-processamento e classificação dos dados. (a) Pré-processamento, (b) classificação dos dados.

Fonte: Autoria própria.

O histograma da Figura 19 exibe os valores de comprimento de onda de todo o conjunto de dados coletado. Nesse histograma, o eixo das abscissas mostra o valor de comprimento de onda para cada material, enquanto o eixo das ordenadas mostra o número de ocorrências de cada valor. Observa-se que os valores para classe *plasticina_B* possuem valores agrupados entre 1.545,70 nm e 1.545,72 nm, enquanto os valores de comprimento de onda para os demais materiais se concentram entre 1.545,91 nm e 1.545,96 nm. Os histogramas individuais para cada material podem ser visualizados na Figura 20.

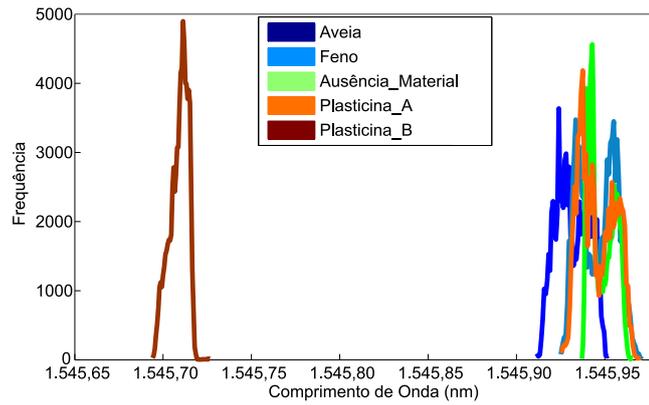


Figura 19: Histograma das classes *in vitro*.

Fonte: Autoria própria.

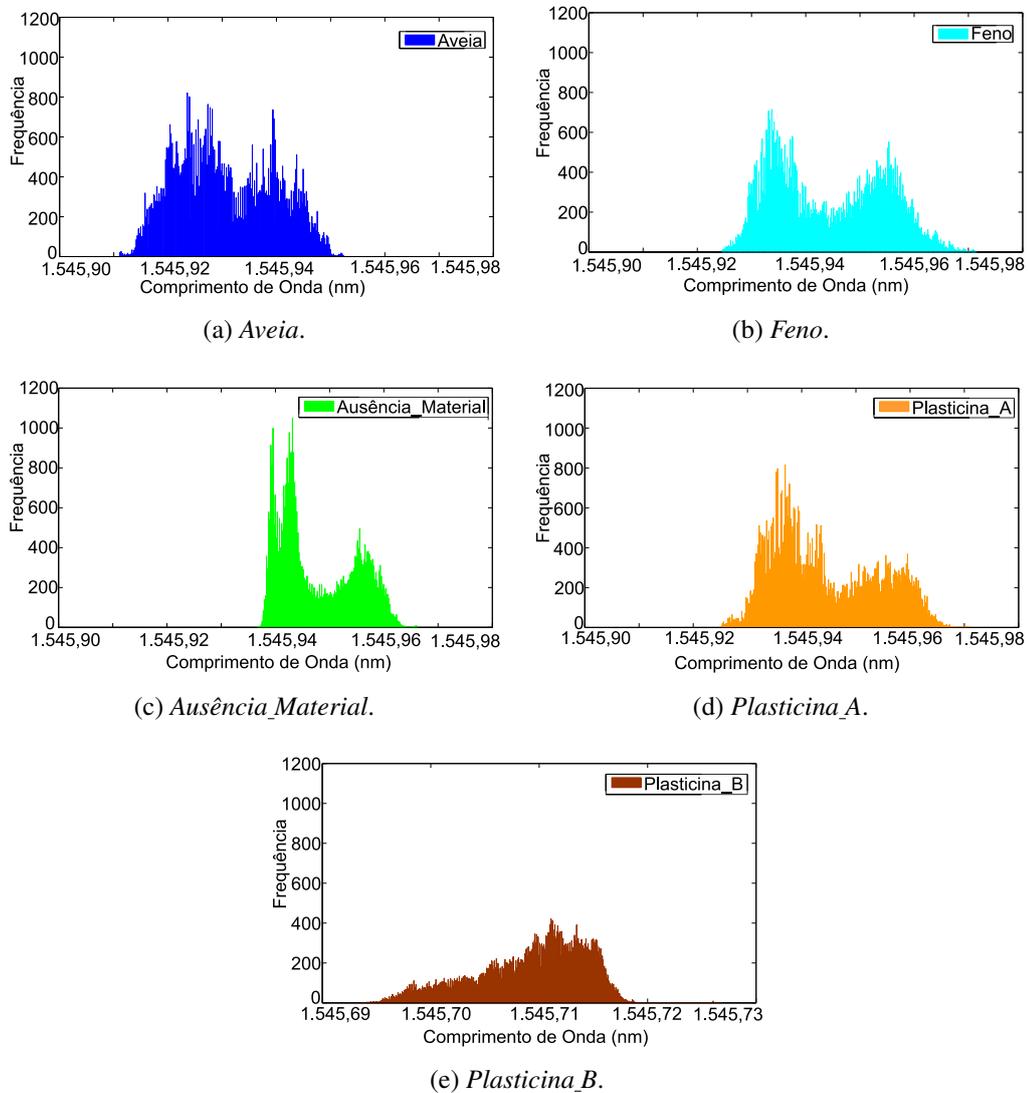


Figura 20: Histograma dos sinais de mastigação *in vitro*. Classe: (a) *aveia*, (b) *feno*, (c) *ausência_material*, (d) *plasticina_A* e (e) *plasticina_B*.

Fonte: Autoria própria.

A Figura 21 exibe uma amostra do conjunto de dados referentes a 6 segundos de simulação para cada material. Observa-se que cada um dos materiais possui forma de onda específica e, para alguns materiais, valores de comprimento de onda diferentes, isso devido à textura relacionada a cada material.

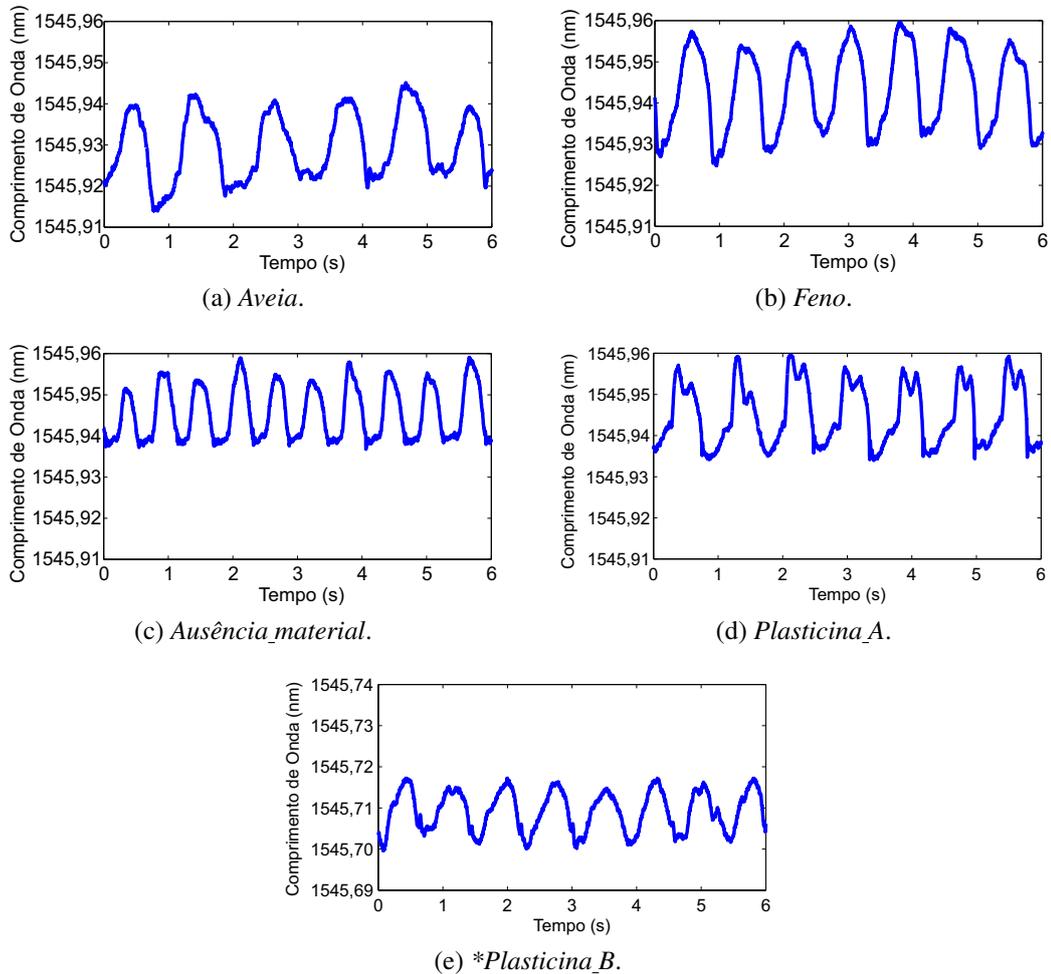


Figura 21: Sinais de mastigação para: (a) *aveia*, (b) *feno*, (c) *ausência_material*, (d) *plasticina_A* e (e) *plasticina_B*.

*Os valores associados à *plasticina_B* estão em escala diferente para uma melhor visualização.

Fonte: Autoria própria.

Na Figura 21(a) é possível observar que os dados referentes à *aveia* possuem comprimento de onda entre 1.545,91 nm e 1.545,95 nm, diferenciando-se dos demais materiais. Os dados referentes as mastigações com *feno* e *plasticina_A*, mostrados nas Figuras 21(b) e 21(d), respectivamente, apresentam comprimento de onda semelhantes, com valores entre 1.545,92 nm e 1.545,97 nm, dado que também pode ser observado nos histogramas presentes nas Figuras 20 (b) e (d).

As mastigações referentes à *ausência_material* possuem comprimento de onda entre

1.545,93 nm e 1.545,96 nm. O padrão gerado pode ser observado na Figura 21(c). Já a *plasticina_B* possui comprimento de onda com valores diferentes dos demais, com valores entre 1.545,70 nm e 1.545,72 nm. A forma de onda e os diferentes valores de comprimento de onda são importantes, pois caracterizam os materiais. As características específicas de cada material podem ser importantes durante a etapa de treinamento dos classificadores, influenciando na classificação de cada material.

A partir dos dados coletados foram gerados três conjuntos de treinamento: $\tilde{N}Segmentado_{vitro}$, $\tilde{N}SegmentadoFFT_{vitro}$ e $SegmentadoFFT_{vitro}$, no qual $\tilde{N}Segmentado_{vitro}$ representa um conjunto de dados com cada instância composta por um segundo de mastigação. $\tilde{N}SegmentadoFFT_{vitro}$ representa o conjunto de treinamento com cada instância composta por um segundo de mastigação em conjunto com as componentes de frequência desse sinal e, $SegmentadoFFT_{vitro}$ representa o conjunto com os dados segmentados a cada movimento de mastigação em conjunto com as componentes de frequência desse sinal. A seguir é apresentada a composição de cada um dos três conjuntos de treinamento criados no ensaio *in vitro*.

A. Conjunto $\tilde{N}Segmentado_{vitro}$

Para criação do conjunto de treinamento $\tilde{N}Segmentado_{vitro}$, os dados foram divididos em 400 instâncias $\overline{\tilde{N}Segmentado_{vitro_i}}$, sendo representadas por

$$\tilde{N}Segmentado_{vitro} = \{ \overline{\tilde{N}Segmentado_{vitro_1}}, \overline{\tilde{N}Segmentado_{vitro_2}}, \dots, \overline{\tilde{N}Segmentado_{vitro_{400}}} \}, \quad (27)$$

onde cada instância $\overline{\tilde{N}Segmentado_{vitro_i}}$ é composta por 1 segundo de mastigação para cada material e contém 1000 atributos previsores sendo que cada $\overline{\tilde{N}Segmentado_{vitro_i}} \in \tilde{N}Segmentado_{vitro}$ e possui um rótulo associado. Esse rótulo define a classe a qual a instância pertence. Assim,

$$\overline{\tilde{N}Segmentado_{vitro_i}} = (\vec{x}_i, y_i) \quad (28)$$

na qual \vec{x}_i é um vetor de 1000 elementos com os valores que representam os atributos previsores da instância $\overline{\tilde{N}Segmentado_{vitro_i}}$ e y_i é o valor da classe que está associada a essa instância, $y_i \in C_{invitro}$.

B. Conjunto $\tilde{N}SegmentadoFFT_{vitro}$

Com a hipótese de melhorar os resultados da classificação, um segundo conjunto de treinamento $\widetilde{NSegmentadoFFT}_{Vitro}$ foi gerado. Para obtenção de informações adicionais dos sinais, propõe-se o uso da Transformada Rápida de *Fourier* (FFT) para a extração de informações do espectro de frequências do sinal (COOLEY; TUKEY, 1965). O espectro de frequência é obtido por meio de (HAYKIN; VEEN, 1999)

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-j\frac{2\pi}{N}kn}, \quad 0 \leq k \leq N-1, \quad (29)$$

onde N é o número de amostras contidas no sinal sob análise. Neste caso, corresponde ao número de amostras em 1 segundo, isto é, $N = 1000$. O conjunto $\widetilde{NSegmentadoFFT}_{Vitro}$ é dado por

$$\widetilde{NSegmentadoFFT}_{Vitro} = \{ \overline{\widetilde{NSegmentadoFFT}_{Vitro1}}, \overline{\widetilde{NSegmentadoFFT}_{Vitro2}}, \dots, \overline{\widetilde{NSegmentadoFFT}_{Vitro400}} \}. \quad (30)$$

Nesse conjunto, os dados foram divididos em 400 instâncias. Cada instância $\overline{\widetilde{NSegmentadoFFT}_{Vitroi}}$ é formada por 1016 atributos previsores, compostos por 1000 atributos do sinal original (1 segundo de mastigação) adicionados de 16 atributos contendo os 16 primeiros componentes da frequência do sinal, gerados por meio do cálculo da FFT do sinal. Cada elemento $\overline{\widetilde{NSegmentadoFFT}_{Vitroi}} \in \widetilde{NSegmentadoFFT}_{Vitro}$ possui um rótulo associado. Esse rótulo define a classe a qual a instância pertence. Assim,

$$\overline{\widetilde{NSegmentadoFFT}_{Vitroi}} = (\vec{x}_i, y_i), \quad (31)$$

na qual \vec{x}_i é um vetor de 1016 elementos com os valores que representam os atributos previsores da instância $\overline{\widetilde{NSegmentadoFFT}_{Vitroi}}$ e y_i é o valor da classe que está associada a essa instância, e $y_i \in C_{invitro}$.

O Algoritmo 3 descreve a sequência de passos realizados para geração do conjunto de treinamento $\widetilde{NSegmentadoFFT}_{Vitro}$. É considerada como entrada para o algoritmo um conjunto com os 400 segundos de amostras coletadas, o qual contém a união dos 80 segundos de mastigação de cada classe. No *passo 1* do algoritmo são criadas as instâncias $\overline{\widetilde{NSegmentadoFFT}_{Vitroi}}$ com 1000 atributos cada. Na sequência, é realizado o cálculo da FFT e as 16 primeiras componentes de frequência são adicionadas ao sinal. Por fim, cada uma das instâncias é adicionada ao conjunto de treinamento $\widetilde{NSegmentadoFFT}_{Vitro}$. Foram selecionadas apenas as 16 primeiras componentes de frequência do sinal, pois durante a etapa de treinamento

dos classificadores foram os atributos que obtiveram os melhores resultados.

Algoritmo 3 Formação do conjunto de treinamento $\tilde{N}SegmentadoFFT_{V\acute{i}tro}$

Entrada: Conjunto de dados D contendo os dados de mastigação

Saída: Conjunto de treinamento $\tilde{N}SegmentadoFFT_{V\acute{i}tro}$

```

início
   $k \leftarrow 1$ ;
  //Cria 400 instâncias para o conjunto de dados
  para  $i \leftarrow 1$  até  $i \leq 400$  faça
    //Passo 1.
    para  $j \leftarrow ((1000 * i) - 999)$  até  $(j \leq 1000 * i)$  faça
       $\tilde{N}SegmentadoFFT_{V\acute{i}tro}[k] \leftarrow D[j]$ ;
       $k \leftarrow k + 1$ ;
    fim
    //Passo 2.
     $Vetor\_FFT \leftarrow FFT(\tilde{N}SegmentadoFFT_{V\acute{i}tro})$ ;
    //Adiciona as 16 primeiras componentes de frequência para cada instância
    para  $f \leftarrow 1$  até  $f \leq 16$  faça
       $\tilde{N}SegmentadoFFT_{V\acute{i}tro}[1000 + f] \leftarrow Vetor\_FFT[f]$ ;
    fim
     $\tilde{N}SegmentadoFFT_{V\acute{i}tro}[i] \leftarrow \tilde{N}SegmentadoFFT_{V\acute{i}tro}$ ;
  fim
fim

```

C. Conjunto $SegmentadoFFT_{V\acute{i}tro}$

Surgiu então uma nova hipótese para melhorar o conjunto de dados de treinamento. É possível observar, na Figura 22, que para a classe *ausência_material*, 1 segundo de amostra coletada não corresponde exatamente a um movimento de abertura e fechamento de mandíbula (movimento de mastigação). Tal comportamento pode sofrer variações de acordo com a classe a qual o movimento está associado. Por exemplo, os movimentos de mastigação realizados com *aveia* e *feno* possuem 1 segundo (1000 atributos), mas os movimentos realizados com *plasticina_A* levam cerca de 0,8 segundos, possuindo 800 atributos. Assim, os sinais de mastigação foram pré-processados para extrair apenas os sinais correspondentes a um movimento de mastigação, mesmo quando a duração do movimento é inferior a 1 segundo (1000 atributos). Nos movimentos com duração menor que 1 segundo, ou seja, menos de 1000 atributos, o restante dos atributos faltantes até completar 1000 foram preenchidos com o valor médio do sinal, pois, durante a etapa de classificação com os algoritmos observou-se que o valor médio do sinal é um atributo que melhora o resultado do classificador.

O terceiro conjunto de treinamento $SegmentadoFFT_{V\acute{i}tro}$ também possui um total de 400 instâncias. Cada instância $SegmentadoFFT_{V\acute{i}tro}_i$ possui 1016 atributos previsores. Os primeiros 1000 atributos são formados por 1 movimento de mastigação. Para os 16 atributos restantes foram adicionados os 16 primeiros componentes da frequência do sinal gerados por meio do cálculo da FFT. A Figura 23 mostra a FFT de um movimento de mastigação para cada material.

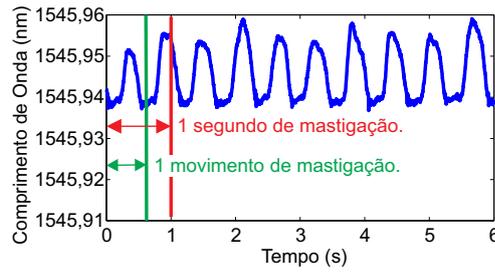


Figura 22: Sinal de mastigação da classe *ausência_material*.

Fonte: Autoria própria.

Nas Figuras 23 (a) à 23 (e), as frequências fundamentais são 1 Hz, 1,25 Hz, 1,20 Hz, 1,11 Hz e 1,5 Hz, respectivamente. Diferentes amplitudes nas componentes de frequência refletem em diferentes formas de onda. Diferentes frequências fundamentais refletem em sinais com diferentes períodos. Portanto, o uso do espectro de frequência do sinal pode auxiliar no processo de treinamento dos classificadores com o objetivo de identificar diferentes padrões no processo de mastigação de ruminantes.

Comparando o espectro de frequência dos sinais exibidos na Figura 23 com os sinais no domínio do tempo mostrados na Figura 21 é possível observar que as componentes fundamentais de frequência do sinal correspondem aos períodos dos sinais analisados. O primeiro componente de frequência, que é o componente DC do sinal é usado como atributo a_{1001} , assim como os atributos a_{1002} até a_{1016} que são formados pelas 2^a até 15^a componentes de frequência, respectivamente. Esses dados são utilizados durante a etapa de treinamento do algoritmo classificador como atributos previsores. O conjunto $SegmentadoFFT_{Vitro}$ pode ser representado como

$$SegmentadoFFT_{Vitro} = \{\overline{SegmentadoFFT_{Vitro1}}, \overline{SegmentadoFFT_{Vitro2}}, \dots, \overline{SegmentadoFFT_{Vitro400}}\}, \quad (32)$$

onde cada elemento $\overline{SegmentadoFFT_{Vitroi}} \in SegmentadoFFT_{Vitro}$ possui um rótulo associado. Esse rótulo define a classe a qual a instância pertence. Assim,

$$\overline{SegmentadoFFT_{Vitroi}} = (\vec{x}_i, y_i). \quad (33)$$

na qual \vec{x}_i é um vetor de 1016 elementos com os valores que representam os atributos previsores

da instância $\overline{\text{SegmentadoFFT}_{\text{vitro}_i}}$ e y_i é o valor da classe que está associada a essa instância, e $y_i \in C_{\text{in vitro}}$.

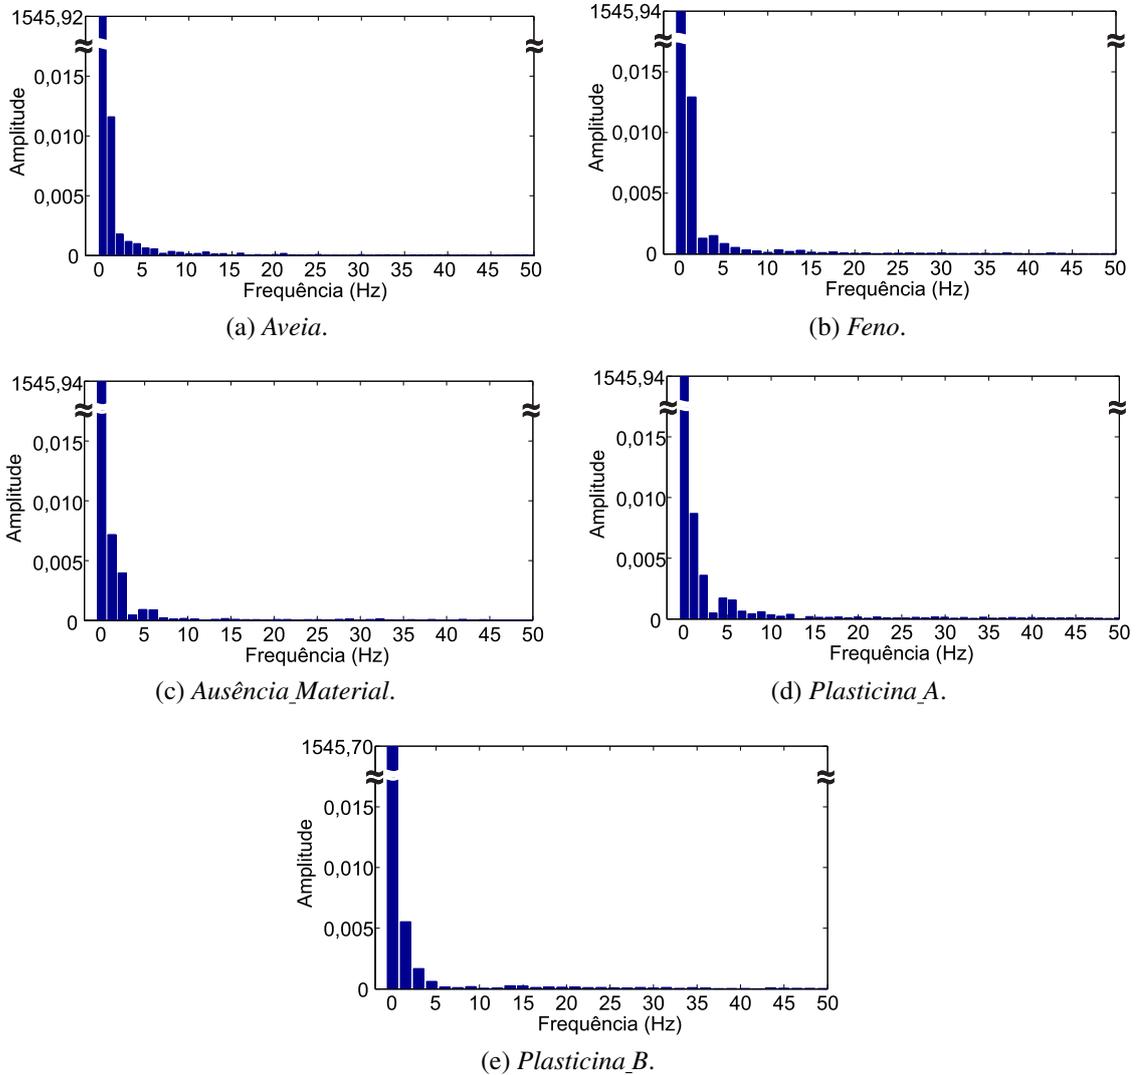


Figura 23: FFT dos sinais de mastigação *in vitro*. Classe: (a) *aveia*, (b) *feno*, (c) *ausência_material*, (d) *plasticina_A* e (e) *plasticina_B*.

Fonte: Autoria própria.

O Algoritmo 4 descreve as etapas necessárias para formação do conjunto de treinamento $\overline{\text{SegmentadoFFT}_{\text{vitro}}}$. Esse algoritmo recebe como entrada um conjunto com os dados de mastigação de uma determinada classe. No *passo 1*, os dados são centralizados em zero antes de serem utilizados pelo algoritmo de segmentação. Devido ao fato dos movimentos serem realizados manualmente, o valor base do sinal sofre variações em alguns instantes de tempo. Por isso, no Algoritmo 5, o qual centraliza o sinal em zero, é calculada a média do sinal a cada dois segundos, a média é então subtraída do sinal original, dessa maneira obtêm-se o sinal na base zero.

Algoritmo 4 Algoritmo que retorna o conjunto de dados *SegmentadoFFT*_{Vitro}.

Entrada: Conjunto de dados $D_{Entrada}$

Saída: Conjunto de dados *SegmentadoFFT*_{Vitro}

início

$inicio \leftarrow 1; fim \leftarrow 0;$
 $i \leftarrow 1; instancia \leftarrow 1;$

//Passo 1.

$vetor_centralizado \leftarrow centralizar_dados(D_Entrada);$ // Algoritmo 5.

//Passo 2.

enquanto $instancia \leq 80$ //Adiciona 80 instâncias ao conjunto de treinamento. **repita**

$p_zero \leftarrow 0;$ //armazena o número de cruzamentos por zero a cada movimento de mastigação.

enquanto $(p_zero < 3$ e $(i < 80000))$ **repita**

se $(vetor_centralizado[i] == 0)$ ou $(vetor_centralizado[i] > 0$ e $vetor_centralizado[i-1] < 0)$

então

$p_zero \leftarrow p_zero + 1;$

se $p_zero \leq 2$ **então**

$i \leftarrow i + 50;$ //Adiciona 50 ao índice evitando encontrar novos cruzamentos por zero muito próximos.

fim

fim

$i \leftarrow i + 1;$

fim

//Passo 3.

$menor_valor \leftarrow 1;$

$indice_menor_valor = -1;$

para $j \leftarrow i$ até $(j < i - 100); j --$ //Procura pelo índice de menor valor. **faça**

se $menor_valor > vetor_centralizado[j]$ **então**

$menor_valor \leftarrow vetor_centralizado[j];$

$indice_menor_valor \leftarrow j;$

fim

fim

$fim \leftarrow indice_menor_valor;$

//Passo 4.

$l = 1;$

para $k \leftarrow inicio$ até $(k < fim)$ //Adiciona os valores do conjunto de dados original a uma nova instância. **faça**

$SegmentadoFFT_{Vitro}[instancia][l] \leftarrow D_Entrada[k];$

$l = l + 1;$

fim

//Passo 5.

$Vetor_FFT \leftarrow FFT(SegmentadoFFT_{Vitro}[instancia]);$

//Passo 6.

se $(fim - inicio - 1) < 1000$ //Adiciona a média do sinal caso o movimento tenha intervalo de menos de 1 segundo. **então**

$ts \leftarrow length(SegmentadoFFT_{Vitro}[instancia]);$

$media \leftarrow \frac{1}{ts} \sum_{k=i}^{ts} D_Entrada[k];$

para $m \leftarrow fim - inicio$ até (1000) **faça**

$SegmentadoFFT_{Vitro}[instancia][m] \leftarrow media;$

fim

fim

//Passo 7.

para $n \leftarrow 1$ até $n \leq 16$ //Adiciona as 16 primeiras componentes de frequência para instância. **faça**

$SegmentadoFFT_{Vitro}[instancia][1000 + n] \leftarrow Vetor_FFT[n];$

fim

$SegmentadoFFT_{Vitro}[instancia] \leftarrow SegmentadoFFT_{Vitro}[instancia];$

$inicio \leftarrow fim + 1;$ O início do próximo sinal é definido.

$i \leftarrow fim + 1;$ O início do próximo sinal é definido.

$fim \leftarrow 0;$

$instancia \leftarrow instancia + 1;$

fim

fim

Algoritmo 5 Algoritmo para centralizar os valores em zero.

```

Entrada: Conjunto de dados  $D\_Entrada$ 
Saída: Conjunto de dados centralizados  $D\_Saida$ 
início
   $n \leftarrow 1999;$ 
  para  $i \leftarrow 0$  até  $i < 80000$  faça
    //Passo 2.
    se  $(i \bmod 2000 == 0)$  ou  $(i == 0)$  então
       $media \leftarrow \frac{1}{2000} \sum_{k=i}^n D\_Entrada[k]; n \leftarrow n + 2000;$ 
    fim
     $D\_Saida[i] \leftarrow D\_Entrada[i] - media;$ 
  fim
fim

```

No *passo 2* do Algoritmo 4, é efetuada a segmentação do sinal a cada movimento de mastigação. Inicialmente, o algoritmo busca no sinal por três cruzamentos por zero. As marcações presentes na Figura 24 demonstram os cruzamentos por zero em um sinal de mastigação. O primeiro e segundo cruzamentos por zero correspondem ao sinal a ser segmentado, e o terceiro faz parte do próximo movimento de mastigação. Ao encontrar o terceiro cruzamento por zero, o algoritmo entra no *passo 3*. Nessa etapa, o algoritmo percorre no conjunto de dados os 100 índices anteriores ao terceiro cruzamento por zero, buscando pelo índice que armazena o menor valor de comprimento de onda. Esse índice indica o final de um movimento de mastigação. O índice seguinte será utilizado como início do próximo movimento de mastigação. O número de 100 índices foi selecionado após testes para verificar em qual posição do conjunto de dados o índice com o início de um movimento de mastigação se encontrava.

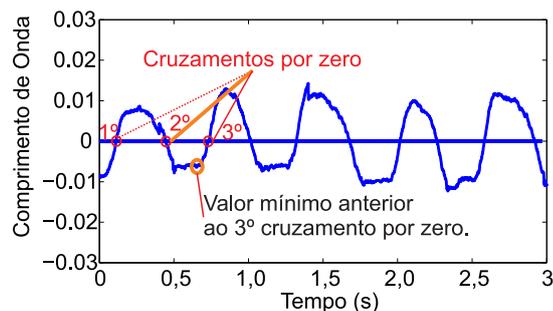


Figura 24: Sinal de mastigação com marcações indicando as passagens por zero.

Fonte: Autoria própria.

Após definidos os índices de início e final de um movimento de mastigação (para o primeiro movimento de mastigação o índice inicial é o de valor 1), no *passo 4* será percorrido o conjunto com os dados originais a fim de adicionar os valores para cada atributo da instância $\overline{SegmentadoFFT}_{Vitro_i}$ do conjunto $SegmentadoFFT_{Vitro}$. No *passo 5* é realizado o cálculo da FFT. Então, caso o movimento de mastigação apresente duração menor que 1 segundo, os atributos faltantes serão completados com o valor médio do sinal, conforme descrito no

passo 6. Por fim, no *passo 7*, as 16 primeiras componentes de frequência são adicionadas a instância $\overline{\text{SegmentadoFFT}}_{\text{V}i\text{tro}i}$, que por sua vez passa a fazer parte do conjunto de treinamento $\text{SegmentadoFFT}_{\text{V}i\text{tro}}$.

A Figura 25 exibe os sinais originais e o movimento de mastigação segmentado após a execução dos algoritmos. Após a segmentação, pode-se observar que as características de cada movimento são preservadas.

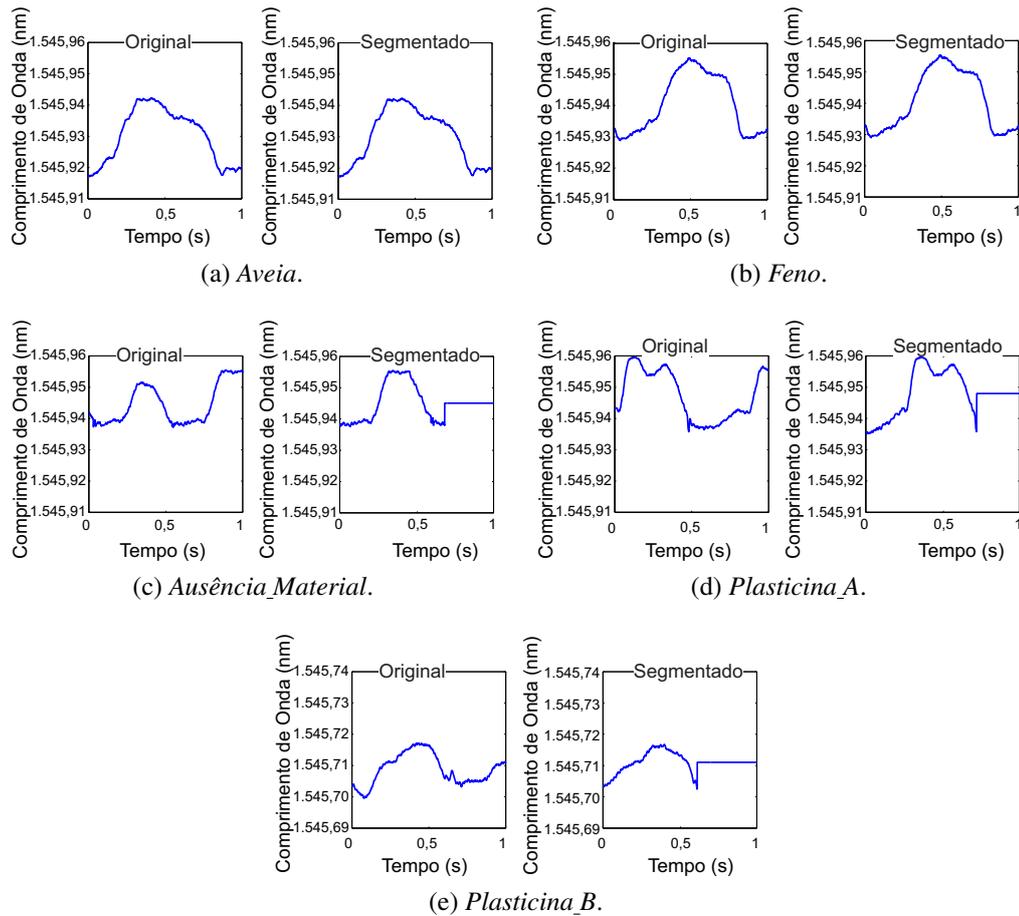


Figura 25: Sinais de mastigação para: (a) *aveia*, (b) *feno*, (c) *ausência material*, (d) *plasticina A* e (e) *plasticina B*.

*Os valores associados à *plasticina B* estão em escala diferente dos demais materiais para melhor visualização.

Fonte: Autoria própria.

4.2 AQUISIÇÃO DOS DADOS *In vivo*

Na seção anterior, foram apresentadas as etapas de aquisição dos dados *in vitro* como forma de verificar a viabilidade do emprego de sensores FBG na aquisição de dados relacionados ao comportamento ingestivo de ruminantes. Nessa seção (4.2), são apresentadas

as etapas realizadas para a aquisição dos dados *in vivo*, como forma de mostrar que os sensores FBG podem ser aplicados para avaliar o comportamento ingestivo de ruminantes durante o processo de alimentação.

Para aquisição dos dados *in vivo*, foi utilizado um bovino da espécie *Bos taurus*, com 2 meses de vida e pesando, aproximadamente 160kg. Para tal, foi realizado um procedimento cirúrgico para a colocação do sensor FGB no maxilar inferior do animal. Para o uso de animais na pesquisa, foi elaborado e enviado um projeto de pesquisa à Comissão de Ética no Uso de Animais (CEUA) da Universidade Tecnológica Federal do Paraná, Campus Dois Vizinhos. O projeto foi aprovado com o parecer CEUA 2013-009 (Anexo A).

Os ensaios envolveram a coleta de dados correspondentes a cinco classes, rotuladas de acordo com o tipo de alimento, ou o evento ingestivo relacionado ao instante de tempo da aquisição do sinal. Estas cinco classes pertencem ao conjunto $C_{in vivo}$

$$C_{in vivo} = \{ração, feno, azevém, ócio, ruminação\}. \quad (34)$$

Foram coletados dados para as classes *ração*, *feno* de Tifton (*Cynodon*), *azevém* (*Lolium multiflorum*), *ócio* e *ruminação*. A *ração* estava na forma de concentrado peletizado. Com o *feno* foi utilizada a pastagem desidratada composta por um percentual menor de água. Com o *azevém* procurou-se utilizar a pastagem recém-colhida e disponibilizá-la no mesmo local em que foram fornecidos os demais alimentos. Escolheu-se alimentos com os quais o animal já estava habituado a fim de evitar sua rejeição a algum alimento durante a coleta dos dados.

A Figura 26 registra as etapas desenvolvidas no processamento dos dados *in vivo*. Na primeira etapa, mostrada na Figura 26 (a), foi realizada a aplicação do sensor, na qual um sensor FBG com comprimento de onda de 1.541 nm foi colado em uma placa de titânio cirúrgico com cola a base de *cianoacrilato*. A placa foi fixada na mandíbula do animal por meio de parafusos cirúrgicos. Todos os materiais utilizados no processo cirúrgico são biocompatíveis, não permitindo rejeição do organismo do animal após a implantação do sensor. O sensor FBG utilizado para aquisição dos dados nesse trabalho é sensível a grandezas físicas de temperatura e deformação, isto devido ao efeito termo ótico e fotoelástico da fibra (OTHONOS; KALLI, 1999). Nesse trabalho não foi observada influência da temperatura nos sinais adquiridos, sendo medida apenas a deformação durante o movimento da mandíbula do animal.

Na segunda etapa, exibida na Figura 26 (b), que consiste na ligação do sensor ao interrogador ótico, foi empregada a mesma metodologia dos ensaios *in vitro*. A taxa de amostragem adotada nos ensaios também foi de 1.000 amostras por segundo.

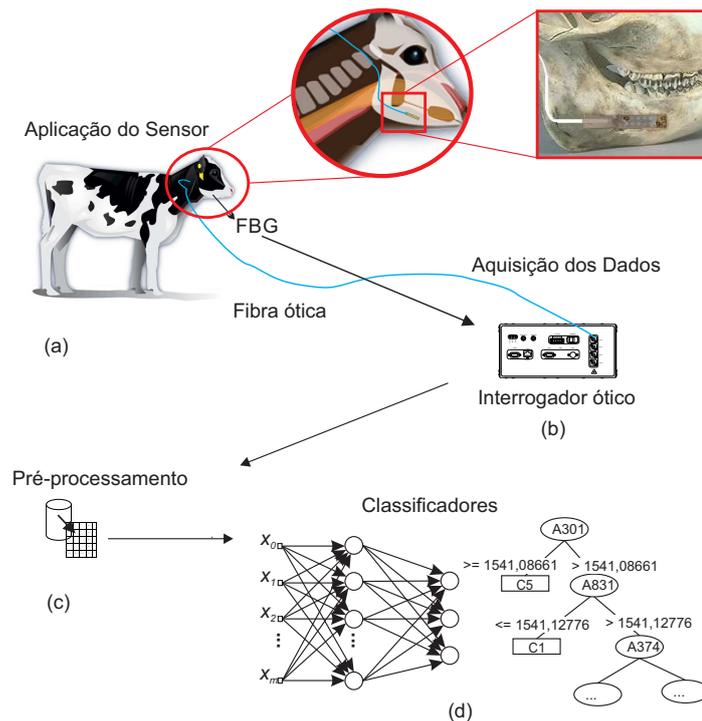


Figura 26: Ilustração das etapas de posicionamento do sensor, aquisição e classificação dos dados. (a) Aplicação do sensor, (b) aquisição dos dados, (c) pré-processamento e (d) classificadores.

Fonte: Autoria própria.

Durante a aquisição dos dados, o animal ficou posicionado em um cercado com aproximadamente 3,5 m x 3 m, no qual recebeu os alimentos em um comedouro padrão. O animal tinha liberdade de movimento dentro do cercado, que foi limitado à cerca de 2 m x 2 m para evitar movimentações bruscas que pudessem interferir na medição e coleta do sinal, bem como as limitações da dimensão do cabo ótico usado para conectar o sensor implantado no animal ao interrogador ótico. Os dados foram adquiridos uma semana após o procedimento cirúrgico.

Todo o processo de coleta de dados foi monitorado em vídeo que, posteriormente, foi utilizado durante a etapa de pré-processamento para rotular os dados de acordo com o material que estava sendo ingerido ou o evento que o animal estava realizando. Um veterinário também esteve presente durante a aquisição dos dados, a fim de verificar o comportamento do animal durante o pastejo.

O primeiro alimento ingerido foi a *ração*, com tempo de ingestão de 13 minutos. O segundo material fornecido ao animal foi o *feno*, com tempo de ingestão de, aproximadamente, 10 minutos. E o terceiro alimento fornecido foi o *azevém*, o qual foi consumido por cerca de

5 minutos. Durante o período de coleta de alimento pelo animal, houve intervalos em que o animal não estava consumindo nenhum alimento. Nesses intervalos foram coletadas as amostras da classe *ócio*. Amostras dessa classe também foram obtidas entre o tempo final da alimentação e o início da *ruminação*. Após, aproximadamente, 45 minutos do final do processo de coleta de todos os alimentos, iniciou-se o processo de *ruminação*, que foi acompanhado por cerca de 15 minutos ¹.

Durante o tempo de coleta dos dados, em alguns momentos, o animal realizou movimentos bruscos com a cabeça, o que gerou ruídos no sinal adquirido. As amostras ruidosas foram descartadas, pois não representavam um movimento de mastigação.

Após a etapa de coleta dos dados, foi realizado o pré-processamento dos arquivos com os dados coletados, no qual os dados foram rotulados de acordo com o tipo de material ou evento realizado. Nessa etapa, foram criados dois conjuntos de treinamento, descritos na seção 4.2.1. Assim como no ensaio *in vitro*, também foi realizado o cálculo da FFT do sinal coletado para cada amostra do material, cuja etapa é mostrada na Figura 26 (c). Na etapa final, mostrada na Figura 26 (d), são gerados os classificadores utilizando RNA e árvore de decisão.

4.2.1 GERAÇÃO DOS CONJUNTOS DE TREINAMENTO

Para gerar o conjunto de treinamento foram utilizadas 200 instâncias para cada classe, totalizando 1000 instâncias nesse conjunto. Mesmo com a aquisição de mais de 5 minutos para cada material, o alimento *azevém* possui 200 amostras, devido ao fato de ser o último alimento fornecido ao animal. Mesmo com 5 minutos de aquisição, existem os momentos de *ócio*, nos quais o animal não está ingerindo o alimento. Para os demais materiais, foram coletadas mais de 200 amostras. Porém, para evitar que os algoritmos fiquem super-ajustados (*overfitting*) para uma determinada classe, foram selecionados, aleatoriamente, o mesmo número de instâncias para cada classe.

Na Figura 27 é apresentado o histograma dos dados adquiridos. No histograma é possível observar a divisão dos valores de comprimento de onda para cada classe. A Figura 28 mostra o histograma dos dados de cada classe do conjunto $C_{in vivo}$.

¹A ruminação inicia quando o animal regurgita o bolo alimentar gerado pelo rúmen à boca, e realiza o processo de remastigação desse bolo. Nesse processo o bolo alimentar é fragmentado em partículas menores que irá favorecer no melhor aproveitamento do alimento pelo animal

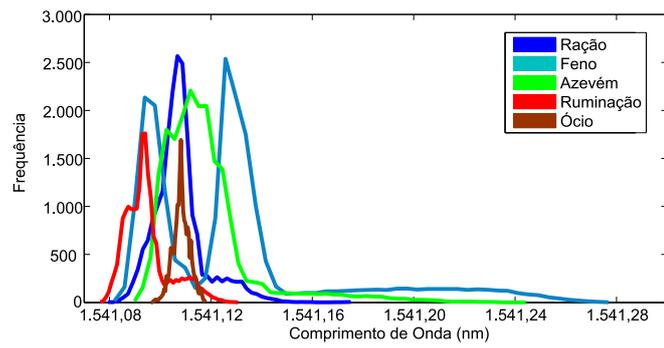


Figura 27: Histograma do conjunto de dados *in vivo*.

Fonte: Autoria própria.

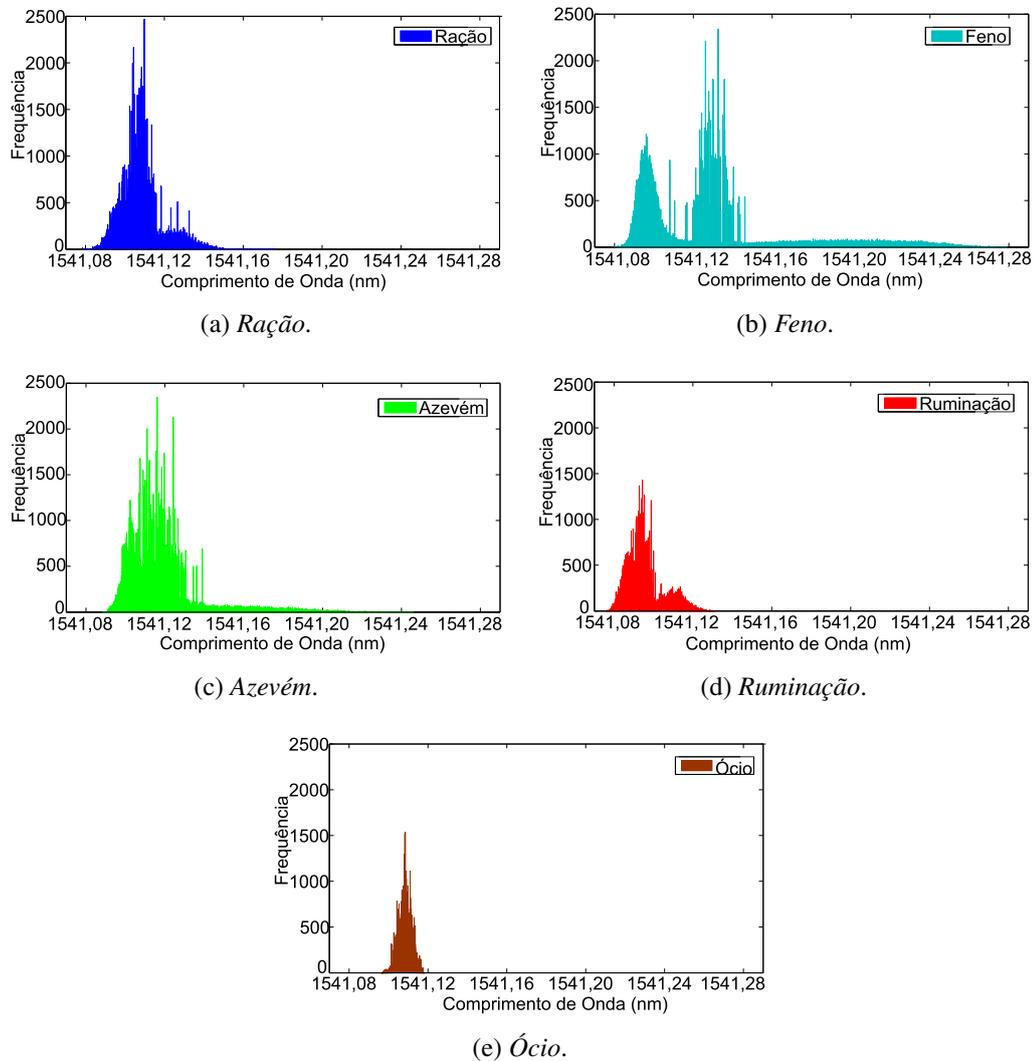


Figura 28: Histograma dos sinais de mastigação *in vivo*. Classe: (a) *ração*, (b) *feno*, (c) *azevém*, (d) *ruminação* e (e) *ócio*.

Fonte: Autoria própria.

A Figura 29 mostra os sinais de mastigação referentes a 6 segundos de dados de cada classe, os quais foram coletados em instantes de tempo aleatórios dentro do conjunto total de dados. Observa-se que o sinal de cada uma das classes gera uma forma e comprimento de onda específico, devido a textura das forrageiras, da composição da *ração* e do bolo alimentar na *ruminação*.

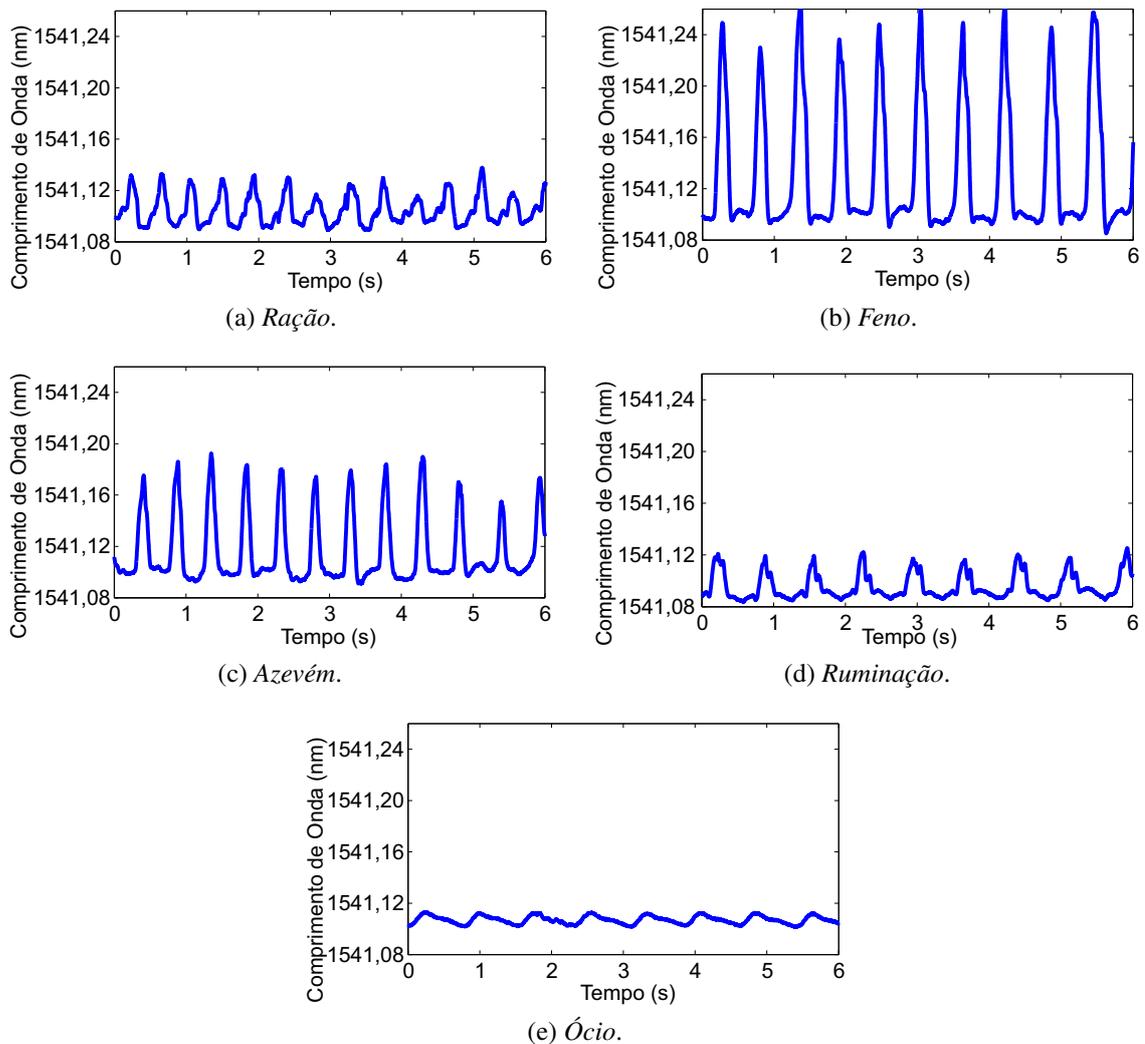


Figura 29: Classe: (a) *ração*, (b) *feno*, (c) *azevem*, (d) *ruminação* e (e) *ócio*.

Fonte: Autoria própria.

Na Figura 29 (a) é possível observar que os dados referentes a *ração* possuem comprimento de onda entre 1541,08 nm e 1541,15 nm, diferenciando dos demais materiais, conforme observado na Figura 28 (a). A pequena alteração na amplitude do comprimento de onda para *ração* está relacionada com as propriedades desse alimento, que estava na forma de concentrado peletizado, que consiste em grãos. Portanto, o animal não realizou grandes movimentos de abertura e fechamento da mandíbula.

Os dados referentes às mastigações com *feno*, exibidos na Figura 29 (b), apresentam comprimento de onda com valores entre 1541,08 nm e 1541,28 nm. O histograma com a frequência dos valores desse material é mostrado na Figura 28 (b). Devido o *feno* estar desidratado, ocasionando ao material uma textura rígida e espessa, o animal teve uma abertura maior da mandíbula para coleta do alimento.

Já a mastigação do *azevém*, exibida na Figura 29 (c), possui comprimento de onda com valores entre 1541,09 nm e 1545,23 nm. Tais valores podem ser observados na Figura 28 (c). O *azevém* recém colhido é composto por uma textura mais macia que o *feno*, gerando menores movimentos de abertura da mandíbula.

A Figura 28 (d) mostra o histograma dos dados relacionados ao processo de *ruminação*. Os valores de comprimento de onda estão entre 1541,08 nm e 1541,13 nm e a Figura 29 (d) mostra a forma de onda dessa classe. O bolo alimentar presente na *ruminação* é um composto pastoso, o qual não demanda grande esforço de mastigação pelo animal.

Os dados da Figura 29 (e), referentes à classe *ócio* apresentam comprimento de onda entre 1541,10 nm e 1541,12 nm. No histograma da Figura 28 (e), é possível observar que, durante o período em que o animal não está se alimentando, existe uma pequena variação no comprimento de onda, diferente dos demais materiais, em que os valores de comprimento de onda sofrem uma variação maior durante cada movimento de mastigação.

Nos dados relacionados à *ração*, *ruminação* e *ócio*, a concentração dos valores de comprimento de onda é maior em determinados intervalos de tempo. Isso se deve ao fato dos movimentos mastigatórios sofrerem alterações menores. Já com o *feno* e *azevém*, os valores se estendem por uma faixa maior de valores, ocasionados pela elevação do sinal no momento de aplicação de maior força pelo animal, bem como influenciado pelas características dos materiais que impõe a mastigação uma maior força.

A. Conjunto *Segmentado*_{vivo}

A partir dos dados adquiridos foram formados os conjuntos de treinamento. Inicialmente, foi gerado o conjunto de treinamento *Segmentado*_{vivo}. Nesse conjunto, cada instância $\overline{\text{Segmentado}}_{\text{vivo}i}$ é formada por 1000 atributos previsores, compostos por 1000 atributos do sinal original. Assim como nos ensaios *in vitro*, 1 segundo de mastigação não corresponde exatamente a um movimento de abertura e fechamento de mandíbula (movimento de mastigação), como pode ser visualizado na Figura 30.

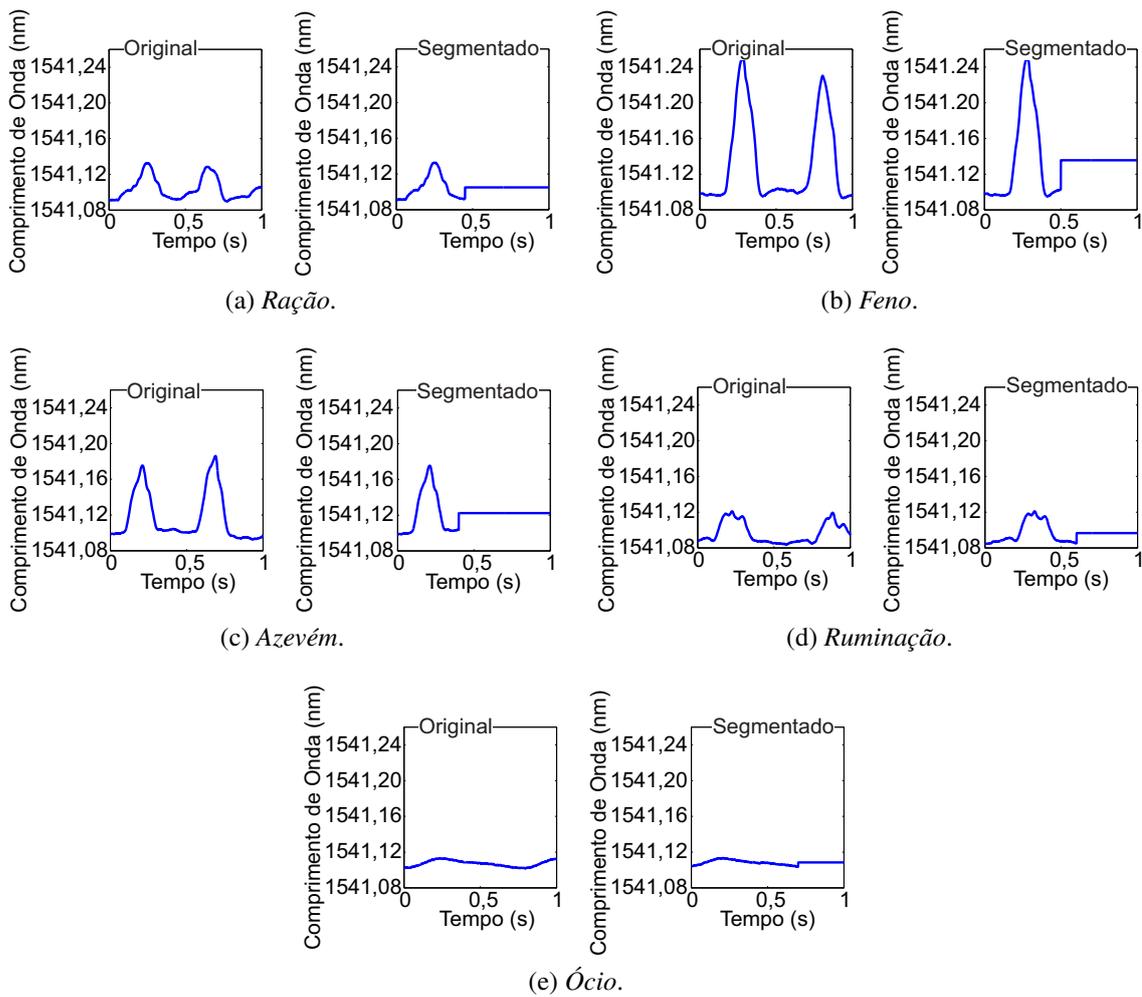


Figura 30: Sinais de mastigação para: (a) *ração*, (b) *feno*, (c) *azevém*, (d) *ruminação* e (e) *ócio*.

Fonte: Autoria própria.

Os movimentos mandibulares possuem variação de 300 a 1000 pontos, ou seja, 0,3 a 1 segundo. Assim, as mastigações com menos de 1000 atributos foram preenchidas com o valor médio do sinal. Os procedimentos para segmentação dos dados e cálculo do valor médio do sinal foram os mesmos empregados nos ensaios *in vitro*. A criação do conjunto $Segmentado_{Vivo}$ é dada por

$$Segmentado_{Vivo} = \{ \overline{Segmentado_{Vivo1}}, \overline{Segmentado_{Vivo2}}, \dots, \overline{Segmentado_{Vivo1000}} \}, \quad (35)$$

onde cada elemento $\overline{Segmentado_{Vivoi}} \in Segmentado_{Vivo}$ possui um rótulo associado. Esse rótulo define a classe a qual a instância pertence. Assim,

$$\overline{Segmentado}_{Vivo_i} = (\vec{x}_i, y_i). \quad (36)$$

na qual \vec{x}_i é um vetor de 1000 elementos com os valores que representam os atributos previsoires da instância $\overline{Segmentado}_{Vivo_i}$ e y_i é o valor da classe que está associada a essa instância, e $y_i \in C_{invivo}$.

B. Conjunto $SegmentadoFFT_{Vivo}$

O conjunto de treinamento $SegmentadoFFT_{Vivo}$ também possui um total de 1000 instâncias. Cada instância $\overline{SegmentadoFFT}_{Vivo_i}$ possui 1030 atributos previsoires. Os primeiros 1000 atributos são formados por 1 movimento de mastigação, e para os 30 atributos restantes, foram adicionados os 30 primeiros componentes da frequência do sinal, gerados com o cálculo da FFT. Os demais componentes da frequência do sinal foram descartados por não gerarem melhorias significativas durante o treinamento dos classificadores. Isso foi observado após testes com diferentes números de atributos. A Figura 31 mostra a FFT de um movimento de mastigação para cada material.

Nas Figuras 31 (a) à 31 (e), as frequências fundamentais são 2,49 Hz, 1,66 Hz, 2 Hz, 1,66 Hz e 1.54 Hz, respectivamente. Comparando o espectro de frequência dos sinais exibidos na Figura 31 com os sinais no domínio do tempo mostrados na Figura 29 é possível observar que as componentes de frequência do sinal correspondem aos períodos dos sinais analisados. O primeiro componente de frequência, que é o componente DC do sinal é usado como atributo a_{1001} , assim como os atributos a_{1002} até a_{1030} que são formados pelas 2^a até 29^a componentes de frequência, respectivamente.

Nas etapas de segmentação dos dados e cálculo da FFT foi empregada a mesma metodologia dos ensaios *in vitro*. O conjunto $SegmentadoFFT_{Vivo}$ é formado por

$$SegmentadoFFT_{Vivo} = \{\overline{SegmentadoFFT}_{Vivo_1}, \overline{SegmentadoFFT}_{Vivo_2}, \dots, \overline{SegmentadoFFT}_{Vivo_{1000}}\}, \quad (37)$$

onde cada elemento $\overline{SegmentadoFFT}_{Vivo_i} \in SegmentadoFFT_{Vivo}$ possui um rótulo associado. Esse rótulo define a classe a qual a instância pertence. Assim,

$$\overline{SegmentadoFFT}_{Vivo_i} = (\vec{x}_i, y_i) \quad (38)$$

na qual \vec{x}_i é um vetor de 1030 elementos com os valores que representam os atributos previso- res da instância $\overline{SegmentadoFFT}_{Vivo_i}$ e y_i é o valor da classe que está associada a essa instância, e $y_i \in C_{in vivo}$.

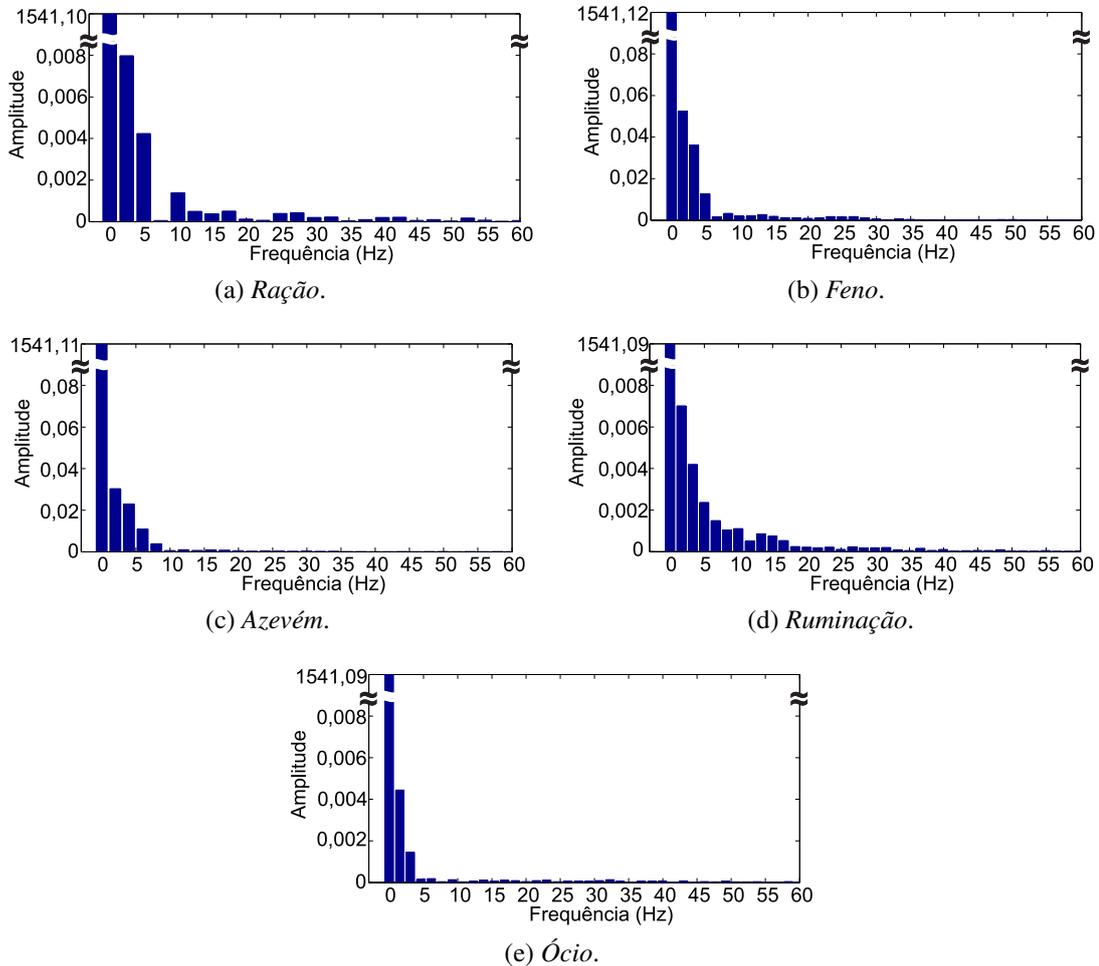


Figura 31: FFT dos sinais de mastigação. Classe: (a) *ração*, (b) *feno*, (c) *azevém*, (d) *ruminação* e (e) *ócio*.

Fonte: Autoria própria.

4.3 APLICAÇÃO DOS ALGORITMOS DE APRENDIZAGEM DE MÁQUINA

Durante a etapa de treinamento dos algoritmos de aprendizagem de máquina foram realizadas três simulações para os dados *in vitro*, sendo uma para cada conjunto de treinamento apresentado na seção 4.1.1 e duas simulações para os dados coletados *in vivo*, de acordo com os conjuntos de treinamento apresentados na seção 4.2.1.

Para dividir o conjunto de dados em treinamento e teste, foram empregadas as técnicas de validação cruzada $k - fold$ e *holdout* (KOHAVI, 1995). Essas técnicas são utilizadas para

avaliar a capacidade de generalização dos algoritmos de aprendizagem de máquina a partir dos conjuntos de dados de treinamento e teste.

No procedimento de validação cruzada $k - fold$, o conjunto de dados é dividido aleatoriamente em k subconjuntos. Destes, $k - 1$ são utilizados para o treinamento e um é utilizado para teste. Esse processo é repetido k vezes até que todos os subconjuntos de dados sejam utilizados no conjunto de teste. Dessa forma, diferentes classificadores são obtidos, e a precisão das classificações dos conjuntos de treinamento e teste podem ser avaliadas.

Na técnica *holdout*, o conjunto de treinamento é dividido em dois subconjuntos: um para treinamento e outro para teste. Os conjuntos são mutuamente exclusivos e, na abordagem proposta, os dados foram divididos em 70% para treinamento e 30% para teste.

Todos os testes realizados com a RNA e a árvore de decisão foram utilizando validação cruzada com $10-fold$ e *holdout*. Os resultados se mostraram semelhantes. Por isso, apenas os resultados com o método de validação cruzada serão abordados no próximo capítulo.

Para o treinamento do classificador com a RNA foi empregada uma rede multicamadas treinada com o algoritmo *back-propagation*, usando a função Tangente Hiperbólica Sigmoidal como função de ativação. Foi utilizada a implementação do algoritmo no *software* Matlab[®]. Como critério de parada utilizou-se a função do erro quadrático médio.

Nas simulações com os dados *in vitro*, realizadas com o conjunto de dados $\tilde{N}Segmentado_{vitro}$, a RNA é estruturada com 1000 neurônios de entrada e 10 neurônios na camada oculta. A camada de saída possui 5 neurônios, um para cada classe: *aveia*, *feno*, *ausência_material*, *plasticina_A*, *plasticina_B*. A arquitetura da RNA é ilustrada na Figura 32.

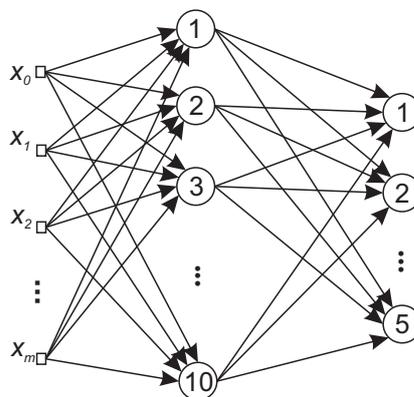


Figura 32: Estrutura da rede neural para o conjunto de treinamento $\tilde{N}Segmentado_{vitro}$.

Fonte: Autoria própria.

A segunda e terceira simulações foram realizadas com o conjunto de treinamento

$\tilde{\text{Segmentado}}FFT_{V_{\text{itro}}}$ e $\text{Segmentado}FFT_{V_{\text{itro}}}$, respectivamente. As RNAs foram geradas com 1016 neurônios na camada de entrada, 10 neurônios na camada oculta e 5 neurônios na camada de saída.

Os dados obtidos no ensaio *in vivo* geraram dois conjuntos de treinamento: $\text{Segmentado}_{V_{\text{ivo}}}$ e $\text{Segmentado}FFT_{V_{\text{ivo}}}$. Com o conjunto $\text{Segmentado}_{V_{\text{ivo}}}$ foi estruturada uma RNA contendo 1000 neurônios na camada de entrada, 10 neurônios na camada oculta e 5 neurônios na camada de saída que representam as classes do conjunto C_{invivo} . A RNA treinada com o conjunto $\text{Segmentado}FFT_{V_{\text{ivo}}}$ é composta por 1030 neurônios na camada de entrada e 10 neurônios na camada oculta. A camada de saída também possui 5 neurônios.

Para a criação do classificador usando árvore de decisão foi empregado o algoritmo J48, implementado da ferramenta Weka (WEKA, 2014). Para treinar o algoritmo de árvore de decisão foram submetidos os conjuntos de treinamento formados com os dados obtidos nos ensaios *in vitro* e *in vivo*. Para reduzir o risco de *overfitting* da árvore de decisão, o algoritmo foi utilizado o método de pós-poda (QUINLAN, 1993; ESPOSITO et al., 1997). A pós-poda visa generalizar a árvore de decisão construída durante a fase de treinamento. A pós-poda consiste na remoção de vértices de decisão da árvore que não contribuem para a sua capacidade de generalização. A poda reduz a complexidade do conjunto de regras induzidas melhorando a precisão e reduz o *overfitting* (QUINLAN, 1987; KIM, 1995).

4.4 CONSIDERAÇÕES FINAIS

Este capítulo descreveu o procedimento de instrumentação, aquisição, e o pré-processamento dos dados obtidos nos ensaios *in vitro* e *in vivo*. Na etapa de pré-processamento foi descrita a preparação dos conjuntos de dados necessários para o treinamento dos classificadores. Ainda nessa etapa, com o objetivo de melhorar o desempenho dos classificadores, novas características foram extraídas dos sinais por meio do cálculo da FFT.

No decorrer deste Capítulo também pode ser observado que existem semelhanças entre os dados coletados nos procedimentos *in vitro* e *in vivo*. Isso permitiu que os testes realizados com os dados *in vitro* servissem como base para os estudos realizados *in vivo*. Os resultados da classificação dos dados com RNA e árvore de decisão são apresentados no Capítulo 5.

5 RESULTADOS EXPERIMENTAIS

Este capítulo apresenta os resultados dos classificadores desenvolvidos com base em RNA e em árvore de decisão para a classificação dos dados obtidos nos ensaios *in vitro* e *in vivo*. Ao final do capítulo, os resultados obtidos são comparados e as vantagens e desvantagens de cada abordagem são destacadas.

5.1 RESULTADOS DOS ENSAIOS *In vitro*

Para o treinamento dos classificadores nos ensaios *in vitro* foram utilizados os três conjuntos de dados apresentados na seção 4.1.1: $\tilde{N}Segmentado_{V_{itro}}$, $\tilde{N}SegmentadoFFT_{V_{itro}}$ e $SegmentadoFFT_{V_{itro}}$. Esses conjuntos representam, respectivamente: os dados originais segmentados a cada 1 segundo de mastigação; os dados originais com 1 segundo de mastigação em conjunto com as componentes de frequência do sinal; e o sinal segmentado a cada movimento de mastigação em conjunto com as componentes de frequência do sinal.

5.1.1 RESULTADOS OBTIDOS COM O USO DE RNA

Nesta seção são exibidos os resultados do treinamento das RNAs para os conjuntos: $\tilde{N}Segmentado_{V_{itro}}$, $\tilde{N}SegmentadoFFT_{V_{itro}}$ e $SegmentadoFFT_{V_{itro}}$.

5.1.1.1 RESULTADOS PARA O CONJUNTO DE TREINAMENTO $\tilde{N}Segmentado_{V_{itro}}$

O resultado da simulação com os 5 materiais (*aveia*, *feno*, *ausência_material*, *plasticina_A* e *plasticina_B*), utilizando o conjunto de treinamento $\tilde{N}Segmentado_{V_{itro}}$ pode ser visto na matriz de confusão na Tabela 7. Lembrando que $\tilde{N}Segmentado_{V_{itro}}$ é composto pelos dados originais divididos a cada 1000 pontos. Essa tabela mostra a matriz confusão gerada após o treinamento e teste dos dados. Na Tabela 7 as células diagonais mostram o número de casos classificados corretamente, enquanto que as demais células mostram os casos classificados incorretamente. A rede neural artificial foi treinada até o ciclo 45, quando a taxa de erro do

conjunto de teste começou a aumentar. Nesse ponto, o treinamento foi interrompido, pois a rede estava perdendo a capacidade de generalização.

Tabela 7: Matriz confusão da RNA com 5 padrões de mastigação para as simulações com o conjunto de treinamento $\tilde{N}Segmentado_{vitro}$.

	1	2	3	4	5
1	80 (100%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)
2	0 (0,00%)	19 (23,75%)	13 (16,25%)	47 (58,75%)	1 (1,25%)
3	0 (0,00%)	3 (3,75%)	74 (92,50%)	3 (3,75%)	0 (0,00%)
4	0 (0,00%)	18 (22,50%)	9 (11,25%)	53 (66,25%)	0 (0,00%)
5	0 (0,00%)	0 (0,00%)	1 (1,25%)	1 (1,25%)	78 (97,50%)

(1) *Aveia*; (2) *Feno*; (3) *Ausência_material*; (4) *Plasticina_A*; (5) *Plasticina_B*.¹

No treinamento da RNA os parâmetros taxa de aprendizagem e termo *momentum* foram ajustados. A taxa de aprendizagem determina a dimensão do ajuste dos pesos a cada iteração durante o treinamento da RNA. Já o termo *momentum* é utilizado para aumentar a velocidade de treinamento da rede. Para a taxa de aprendizado recomenda-se atribuir $0,2 \geq \eta \leq 0,8$ enquanto que para o termo *momentum* $0,3 \geq \alpha \leq 0,7$, podendo esses valores serem alterados de acordo com o domínio do problema (REFENES et al., 1994; ATTOH-OKINE, 1999; KUAN; WHITE, 1994). Os valores definidos para a taxa de aprendizagem e termo *momentum* foram, respectivamente, 0,5 e 0,7, os quais foram utilizados durante todos os experimentos. Esses valores foram obtidos após simulações, onde foi levado em consideração a quantidade de épocas de treinamento e capacidade de generalização do classificador. Quando atribuídos valores mais próximos de 1 para a taxa de aprendizagem e termo *momentum* o treinamento ocorreu mais rapidamente, porém a capacidade de generalização do classificador diminuiu. Então, esses valores foram decrescidos até encontrar um ponto em que a capacidade de generalização não sofresse alteração.

A Tabela 7 mostra, também, os detalhes da classificação para cada classe. Percebe-se que a classificação da classe 1 (*aveia*) obteve 100% de acerto. No sinal coletado para *aveia*, mostrado na Figura 21 (a), verifica-se que esse é o único sinal que apresenta comprimento de onda com valores entre 1545,91 nm e 1545,94 nm. Para o sinal coletado para *ausência_material*, exibido na Figura 21 (c), 74 das 80 amostras foram classificadas corretamente. O valor de comprimento de onda para *ausência_material* está entre 1545,94 nm e 1545,96 nm. Já a

classificação das classes 2 e 4 (*fenó* e *plasticina_A*) apresentou os menores números de acerto. No caso do *fenó*, apenas 19 das 80 amostras utilizadas foram classificadas corretamente. Para a *plasticina_A*, 53 das 80 amostras foram classificadas corretamente. Observando os sinais para essas duas classes, nas Figuras 21 (b) e (d), verifica-se que o comprimento de onda para ambas as classes varia entre 1545,93 nm e 1545,96 nm. Portanto, mesmo esses dois materiais apresentando forma de onda diferente, os valores de comprimento de onda são semelhantes, o que gerou erro durante a classificação. Por fim, a classificação da classe 5 (*plasticina_B*) obteve 78 amostras classificadas corretamente. O sinal coletado para esse material tem comprimento de onda variando entre 1545,70 nm e 1545,72 nm.

5.1.1.2 RESULTADOS PARA O CONJUNTO DE TREINAMENTO $\tilde{N}SegmentadoFFT_{V_{itro}}$

O resultado da classificação realizada com o conjunto $\tilde{N}SegmentadoFFT_{V_{itro}}$ pode ser visto na matriz de confusão apresentada na Tabela 8. Lembrando que $\tilde{N}SegmentadoFFT_{V_{itro}}$ é formado com os dados originais divididos a cada 1000 pontos com a adição das componentes de frequência do sinal, calculadas por meio da FFT. A rede neural artificial foi treinada até o ciclo 53.

Tabela 8: Matriz confusão da RNA com 5 padrões de mastigação para as simulações com o conjunto de treinamento $\tilde{N}SegmentadoFFT_{V_{itro}}$.

	1	2	3	4	5
1	80 (100%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)
2	0 (0,00%)	21 (26,25%)	12 (15,00%)	46 (57,50%)	1 (1,25%)
3	0 (0,00%)	1 (1,25%)	78 (97,50%)	1 (1,25%)	0 (0,00%)
4	0 (0,00%)	16 (20,00%)	6 (7,50%)	58 (72,50%)	0 (0,00%)
5	0 (0,00%)	0 (0,00%)	1 (1,25%)	1 (1,25%)	78 (97,50%)

(1) *Aveia*; (2) *Feno*; (3) *Ausência_material*; (4) *Plasticina_A*; (5) *Plasticina_B*.

É possível observar uma melhora nos resultados da Tabela 8 quando comparados aos testes realizados com o conjunto de dados originais, exibidos na Tabela 7. Isso ocorreu devido a adição dos dados relacionados à FFT as instâncias do conjunto de treinamento. Os melhores resultados de classificação obtidos durante as etapas de treinamento e teste foram para as classes *aveia*, *ausência_material* e *plasticina_B*. Os materiais com o menor número de acertos, durante

a classificação, foram o *feno* e a *plasticina_A*.

5.1.1.3 RESULTADOS PARA O CONJUNTO DE TREINAMENTO *SegmentadoFFT_{Vitro}*

Os resultados da classificação dos 5 materiais para o conjunto de dados *SegmentadoFFT_{Vitro}*, composto pelos dados segmentados, contendo 1000 pontos e adicionando as componentes de frequência do sinal, via FFT, podem ser vistos na Tabela 9. A rede neural artificial foi treinada até o ciclo 93.

Tabela 9: Matriz confusão da RNA com 5 padrões de mastigação para as simulações com o conjunto de treinamento *SegmentadoFFT_{Vitro}*.

	1	2	3	4	5
1	80 (100%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)
2	0 (0,00%)	74 (92,50%)	2 (2,50%)	3 (3,75%)	1 (1,25%)
3	0 (0,00%)	0 (0,00%)	78 (97,50%)	2 (2,50%)	0 (0,00%)
4	0 (0,00%)	6 (7,50%)	2 (2,50%)	64 (80,00%)	8 (10,00%)
5	0 (0,00%)	2 (2,50%)	4 (5,00%)	7 (8,75%)	67 (83,75%)

(1) *Aveia*; (2) *Feno*; (3) *Ausência_material*; (4) *Plasticina_A*; (5) *Plasticina_B*.

O uso do conjunto de dados *SegmentadoFFT_{Vitro}* propiciou os melhores resultados de classificação. Ocorreu uma melhora nos resultados para a classificação do *feno*, pois a segmentação dos sinais a cada movimento de mastigação, juntamente com os dados das componentes de frequência do sinal, o que permitiu diferenciá-lo das mastigações realizadas com a *plasticina_A*. A classificação dos demais materiais apresentou desempenho semelhante ao dos testes exibidos nas seções 5.1.1.1 e 5.1.1.2. A classificação da *plasticina_B* é exceção devido ao fato de que alguns componentes de frequência desse sinal serem similares aos de outros materiais. Como pode ser observado nas Figuras 23 (d), (e), as componentes de frequência de 6 a 12 possuem valores próximos para as classes *plasticina_B* e *plasticina_A*. Portanto, houve um número maior de erros durante a classificação.

Na Tabela 10 é mostrado o resultado final da classificação realizada com base em todos os conjuntos de treinamento. Nessa tabela são exibidas as taxas de erro e acerto geral.

Tabela 10: Resultado geral de erros e acertos nos testes realizados com RNA.

Conjunto de Treinamento	Erros	Acertos
Dados não segmentados - $\tilde{N}Segmentado_{V_{itro}}$	24,00%	76,00%
Dados não segmentados e FFT - $\tilde{N}SegmentadoFFT_{V_{itro}}$	21,25%	78,75%
Dados segmentados e FFT- $SegmentadoFFT_{V_{itro}}$	9,25%	90,75%

Observando os resultados gerados pela rede neural artificial é possível concluir que o maior índice de erros ocorreu nas classes com valores de comprimento de onda médios (entre 1545,93 nm e 1545,96 nm). Mesmo para a *plasticina_A* e para o *feno*, exibidos nas Figuras 21 (b) e (d), que possuíam diferentes formas de onda, houve grande quantidade de erros durante sua classificação. Nota-se, também, que a adição dos dados relacionados à FFT no conjunto de treinamento com os dados originais melhorou os resultados. Porém, o recorte dos dados para cada movimento de mastigação apresentou os maiores índices de acerto. Com o uso do recorte da forma de onda, as características específicas relacionadas a mastigação de cada material foram mantidas ao se selecionar apenas o movimento de abertura e fechamento da mandíbula.

5.1.2 RESULTADOS OBTIDOS COM O USO DE ÁRVORE DE DECISÃO

Para o treinamento do algoritmo de árvore de decisão também foram utilizados os três conjuntos de treinamento: $\tilde{N}Segmentado_{V_{itro}}$, $\tilde{N}SegmentadoFFT_{V_{itro}}$ e $SegmentadoFFT_{V_{itro}}$. Nesta seção são exibidas as árvores de decisão geradas para cada conjunto de treinamento, bem como a matriz de confusão com as taxas de acerto e erros.

5.1.2.1 RESULTADOS PARA O CONJUNTO DE TREINAMENTO $\tilde{N}Segmentado_{V_{itro}}$

A Figura 33 ilustra a árvore gerada com o conjunto de treinamento $\tilde{N}Segmentado_{V_{itro}}$. A árvore de decisão gerada é composta por um total de 45 vértices, sendo 23 vértices terminais e 22 vértices decisão. Dos 1000 atributos coletados para cada instância, apenas os 22 que obtiveram maior razão de ganho de informação estão sendo utilizados na estrutura de decisão da árvore. O vértice raiz da árvore é o atributo 301, onde todos os valores de comprimento de onda menores ou iguais a 1545,71 nm foram classificados como sendo *plasticina_B*. A partir desse ponto ocorreu a ramificação da árvore. O próximo vértice de teste utilizou o atributo 831 para classificar algumas instâncias pertencentes a classe *aveia*. Após esse vértice de decisão surgiram subárvores classificando o restante das instâncias pertencentes a *aveia* e as instâncias pertencentes as outras classes.

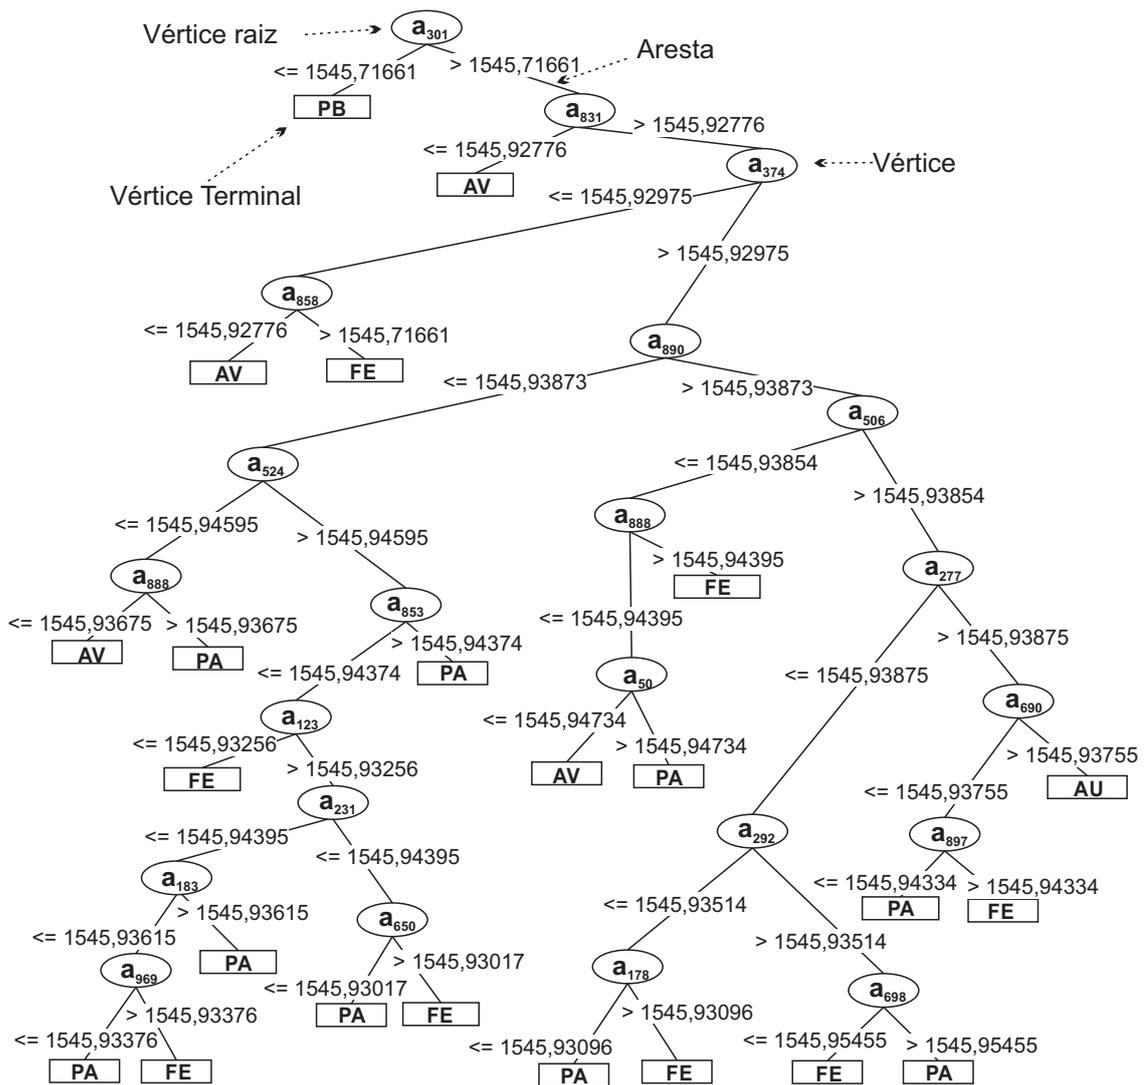


Figura 33: Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento $\tilde{N}Segmentado_{vitro}$.

AV = aveia; FE = feno; AU = ausência material; PA = plasticina A; PB = plasticina B.

Fonte: Autoria própria.

O conhecimento obtido com a aplicação da aprendizagem de máquina é representado por um conjunto de regras ordenadas. A Figura 34 mostra um conjunto de regras ordenadas geradas pelo algoritmo C4.5. A regra R1 é lida da seguinte maneira: “SE (o valor do atributo a_{301} é menor ou igual à 1545,7661nm) então (classe é *plasticina_B*)”.

A Tabela 11 mostra a matriz de confusão para a classificação realizada com base no conjunto de treinamento $\tilde{N}Segmentado_{vitro}$. Para a classe *aveia*, 72 instâncias foram classificadas corretamente e 8 foram classificadas incorretamente. O melhor resultado é referente à classificação da *plasticina_B*, em que todas as 80 instâncias foram classificadas corretamente. Já a *plasticina_A* apresentou o maior número de erros durante a classificação,

com 45 instâncias classificadas incorretamente e 35 corretamente. Nos resultados referentes à classificação do *fenó*, 50 instâncias foram classificadas corretamente e 30 incorretamente. Nas mastigações realizadas para classe *ausência_material*, 78 instâncias foram classificadas corretamente e 2 incorretamente.

R1:	(a301 <= 1545,71661)	
	=> CLASSE= PB	
R2:	(a301 > 1545,71661)	AND
	(a831 <= 1545,92776)	
	=> CLASSE= AV	
[...]		

Figura 34: Conjunto de regras geradas pelo classificador C4.5.

Fonte: Autoria própria.

Tabela 11: Matriz de confusão para resultados obtidos com o algoritmo C4.5 utilizando o conjunto de treinamento $\tilde{N}Segmentado_{vitro}$.

	1	2	3	4	5
1	72 (90,00%)	3 (3,75%)	0 (0,00%)	5 (6,25%)	0 (0,00%)
2	5 (6,25%)	50 (62,50%)	0 (0,00%)	25 (31,25%)	0 (0,00%)
3	0 (0,00%)	0 (0,00%)	78 (97,50%)	2 (2,50%)	0 (0,00%)
4	4 (5,00%)	34 (42,50%)	7 (8,75%)	35 (43,75%)	0 (0,00%)
5	0 (0,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	80 (100%)

(1) *Aveia*; (2) *Feno*; (3) *Ausência_material*; (4) *Plasticina_A*; (5) *Plasticina_B*.

O número de acertos atribuídos à classificação da *plasticina_B* justifica-se pela textura esponjosa e resistente do material, que difere da textura dos demais materiais. Isso gerou valores de comprimento de onda entre 1545,70 nm e 1545,72 nm, como pode ser visto na Figura 21(e).

Os movimentos de mastigação realizados para a classe *ausência_material* mostram acertos superiores aos demais materiais, sendo este o único material em que o comprimento de onda está entre 1545,94 nm e 1545,96 nm. O mesmo ocorreu com a classificação das mastigações realizadas com *aveia*, sendo que o comprimento de onda desse material está entre 1545,92 nm e 1545,94 nm. Essa variação resulta em uma distância maior entre o valor do sinal no início do movimento de mastigação e o pico do sinal. Tal característica também auxilia no processo de classificação dos dados. O número de erros atribuídos à classificação do *fenó* e

da *plasticina_A* justificam-se devido aos valores de comprimento de onda desses dois materiais estarem próximos um do outro (entre 1545,93 nm e 1545,96 nm). Os sinais medidos para estes dois materiais estão exibidos nas Figuras 21(b) e (d), respectivamente.

5.1.2.2 RESULTADOS PARA O CONJUNTO DE TREINAMENTO $\tilde{N}SegmentadoFFT_{Vidro}$

A Figura 35 ilustra a árvore de decisão gerada com o conjunto de treinamento *DF*. A árvore de decisão gerada é composta por um total de 63 vértices, sendo 32 vértices terminais e 31 vértices decisão. O principal fator que diferencia essa árvore para a árvore do conjunto $\tilde{N}Segmentado_{Vidro}$, é a presença de vértices de decisão compostos por atributos superiores ao atributo 1001, o que indica que os dados gerados pela FFT foram utilizados como vértices de decisão.

Observando a árvore de decisão da Figura 38 o primeiro vértice de decisão, formado pelo atributo a_{1015} corresponde à 15^a componente de frequência do sinal. Esse vértice é responsável por dividir a classe *plasticina_B* das demais classes. Outro importante vértice de decisão é formado pelo atributo a_{1001} , o qual corresponde ao nível CC do sinal. Por meio desse atributo são classificadas as instâncias das classes *aveia* e *feno*. O atributo a_{1003} que corresponde à terceira componente de frequência do sinal também é importante na subdivisão das árvores. Esse atributo classifica principalmente as instâncias das classes *ausência_material* e *plasticina_A*.

A Tabela 12 mostra a matriz de confusão após o treinamento do conjunto $\tilde{N}SegmentadoFFT_{Vidro}$. Para a classe *aveia* 76 instâncias foram classificadas corretamente e 4 incorretamente, melhorando a classificação em relação ao conjunto de treinamento $\tilde{N}Segmentado_{Vidro}$. O melhor resultado é referente a *plasticina_B*, em que todas as 80 instâncias foram classificadas corretamente. A classificação dos dados relacionados a *plasticina_A* apresentou melhor desempenho em comparação com a classificação do conjunto de treinamento $\tilde{N}Segmentado_{Vidro}$, passando de 35 para 46 instâncias classificadas corretamente. Já a classificação do *feno* e da *ausência_material* apresentaram um número de acertos menor do que o caso em que se utilizou o conjunto de treinamento $\tilde{N}Segmentado_{Vidro}$. No geral, o classificador gerado com o conjunto de dados $\tilde{N}SegmentadoFFT_{Vidro}$ apresentou maior taxa de acerto. Isso devido a adição dos dados relacionados à FFT como atributos previsores nas instâncias do conjunto de treinamento.

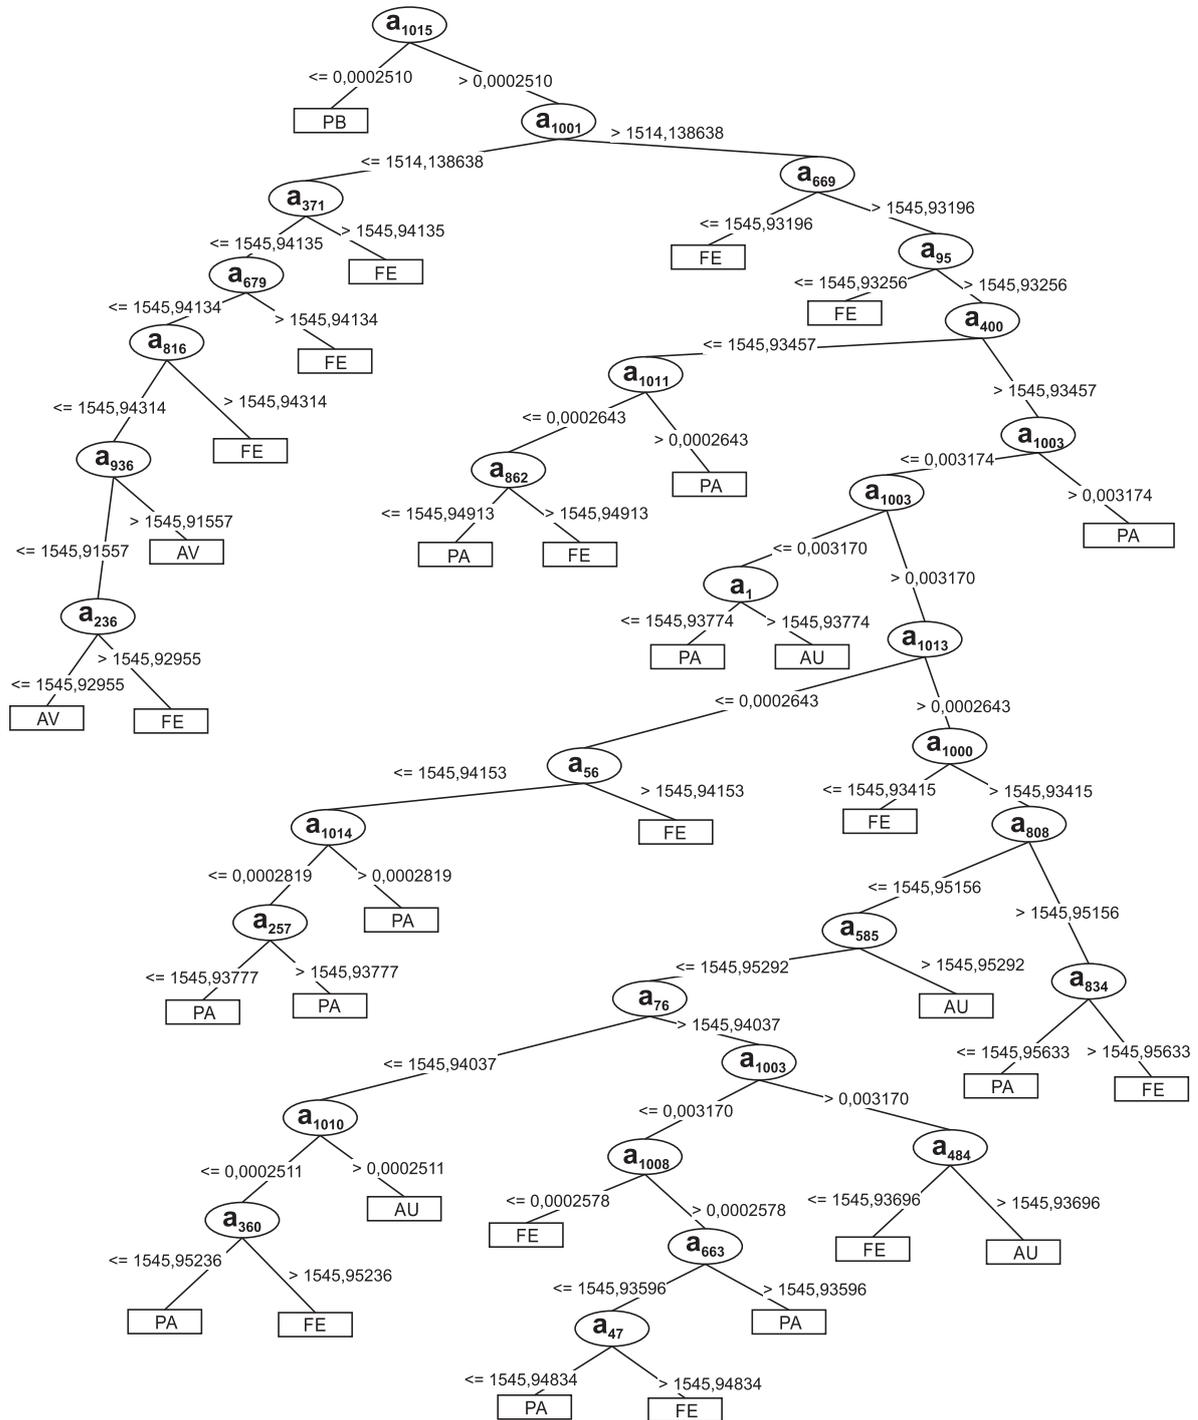


Figura 35: Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento $\tilde{N}SegmentadoFFT_{V\u00edtro}$.

AV = aveia; FE = feno; AU = ausência material; PA = plasticina A; PB = plasticina B.

Fonte: Autoria própria.

Tabela 12: Matriz de confusão para resultados obtidos com o algoritmo C4.5 utilizando o conjunto de treinamento $\tilde{N}SegmentadoFFT_{V\acute{i}tro}$.

	1	2	3	4	5
1	76 (95,00%)	4 (5,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)
2	8 (10,00%)	49 (61,25%)	1 (1,25%)	22 (27,50%)	0 (0,00%)
3	0 (0,00%)	1 (1,25%)	70 (87,50%)	9 (11,25%)	0 (0,00%)
4	0 (0,00%)	18 (22,50%)	16 (20,00%)	46 (57,50%)	0 (0,00%)
5	1 (1,25%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	79 (98,75%)

(1) *Aveia*; (2) *Feno*; (3) *Ausência_material*; (4) *Plasticina_A*; (5) *Plasticina_B*.

5.1.2.3 RESULTADOS PARA O CONJUNTO DE TREINAMENTO $SegmentadoFFT_{V\acute{i}tro}$

A Tabela 13 mostra a matriz de confusão do conjunto de treinamento $SegmentadoFFT_{V\acute{i}tro}$. O classificador gerado apresentou taxas de acerto semelhantes para *aveia* e *plasticina_B* quando comparadas com o conjunto $\tilde{N}SegmentadoFFT_{V\acute{i}tro}$. Quanto aos demais materiais, houve uma melhora significativa no número de acertos, principalmente para as mastigações realizadas com *feno* e *plasticina_A*. Ao recortar o sinal e aplicar a FFT, foi possível gerar atributos adicionais que diferem esses materiais dos demais. O uso desses atributos nas etapas de treinamento e teste possibilitou melhoras nos resultados de classificação.

Tabela 13: Matriz de confusão para resultados obtidos com o algoritmo C4.5 utilizando o conjunto de treinamento $SegmentadoFFT_{V\acute{i}tro}$.

	1	2	3	4	5
1	78 (97,50%)	1 (1,25%)	0 (0,00%)	1 (1,25%)	0 (0,00%)
2	0 (0,00%)	69 (86,25%)	0 (0,00%)	11 (13,75%)	0 (0,00%)
3	0 (0,00%)	1 (1,25%)	76 (95,00%)	3 (3,75%)	0 (0,00%)
4	1 (1,25%)	8 (10,00%)	4 (5,00%)	67 (83,75%)	0 (0,00%)
5	0 (0,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	80 (100%)

(1) *Aveia*; (2) *Feno*; (3) *Ausência_material*; (4) *Plasticina_A*; (5) *Plasticina_B*.

A Figura 36 ilustra a árvore gerada para o conjunto de treinamento $SegmentadoFFT_{vitro}$. A árvore de decisão gerada é composta por um total de 31 vértices, sendo 16 vértices terminais e 15 vértices decisão. A árvore de decisão tem como vértice raiz o atributo 185. O tamanho da árvore diminuiu em relação aos testes anteriores, uma vez que um conjunto menor de atributos foi necessário para formar a estrutura de decisão. A árvore gerada também possui a presença de vértices de decisão compostos por atributos superiores ao atributo 1001, o que indica que os dados gerados pela FFT também foram adotados como vértices de decisão.

O primeiro vértice de decisão presente na árvore de decisão da Figura 38, é formado pelo atributo a_{185} corresponde a um atributo do sinal original. Esse vértice é responsável por dividir a classe $plasticina_B$ das demais classes. É possível observar na estrutura da árvore de decisão que os atributos 1004, 1005, 1008 e 1009 são utilizados, principalmente, na classificação dos dados relacionados ao $feno$ e $plasticina_A$. O impacto do uso de atributos advindos da FFT na classificação foi positivo. Os resultados obtidos na classificação, quando comparados com os resultados fornecidos utilizando o conjunto de treinamento criado com os dados originais, provêm menor erro na classificação.

Na Tabela 14 é apresentado o resultado final após as simulações com todos os conjuntos de treinamento. Nota-se uma evolução no número de acertos do classificador gerado, principalmente para o conjunto de treinamento $SegmentadoFFT_{vitro}$.

Tabela 14: Resultado geral de erros e acertos nos testes realizados com Árvore de Decisão.

Conjunto de Treinamento	Erros	Acertos
Dados não segmentados - $\tilde{N}Segmentado_{vitro}$	21,50%	78,50%
Dados não segmentados e FFT - $\tilde{N}SegmentadoFFT_{vitro}$	20,00%	80,00%
Dados segmentados e FFT - $SegmentadoFFT_{vitro}$	7,50%	92,50%

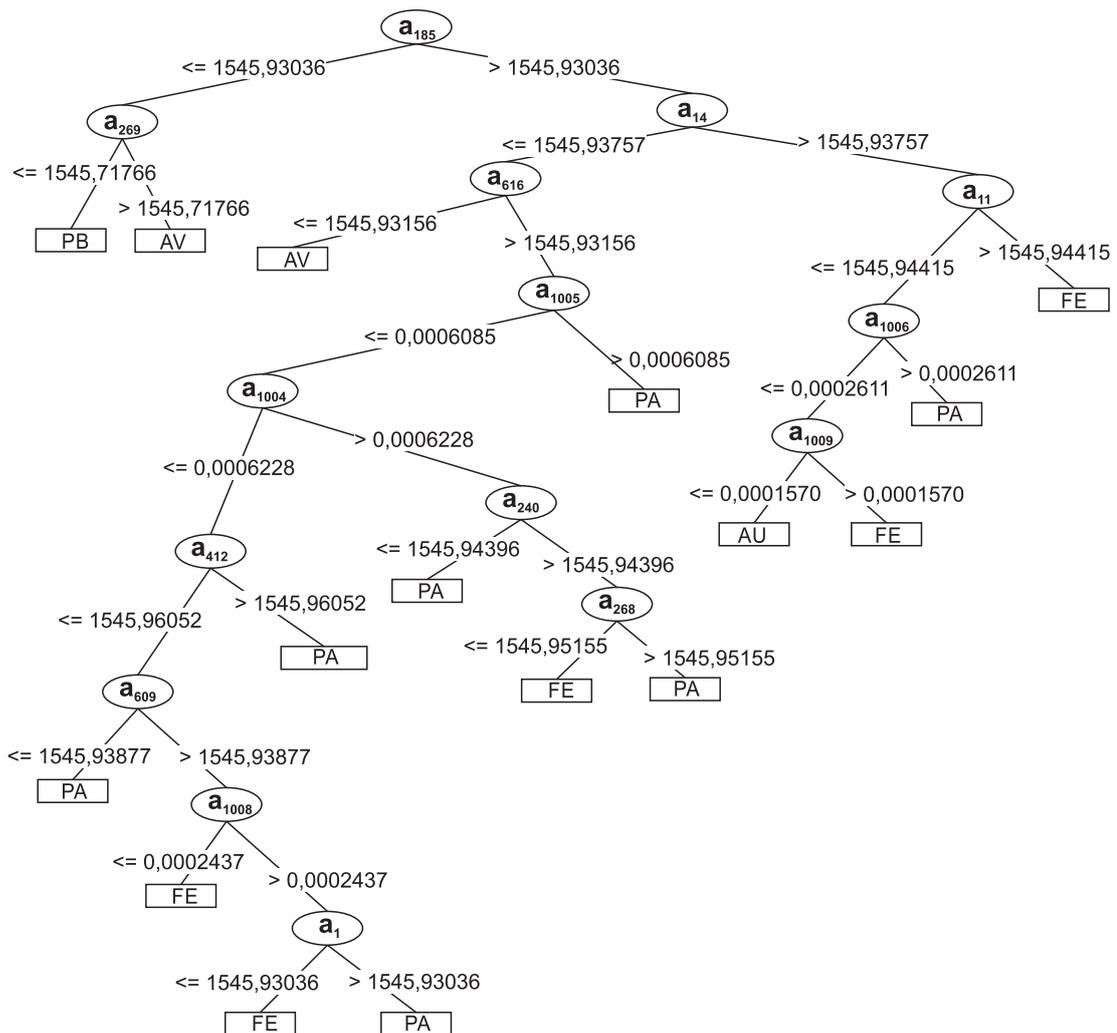


Figura 36: Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento *SegmentadoFFT_{in vitro}*.

AV = *aveia*; FE = *feno*; AU= *ausência material*; PA = *plasticina A*; PB = *plasticina B*.

Fonte: Autoria própria.

5.1.3 RESULTADOS GERAIS PARA O EXPERIMENTO *In vitro*

A Tabela 15 apresenta um resumo dos resultados com a RNA e a árvore de decisão para o ensaio *in vitro*. Como pode ser observado na tabela, as técnicas de aprendizagem de máquina produziram resultados semelhantes quando treinadas com o mesmo conjunto de dados. A etapa de pré-processamento impactou positivamente na melhora dos resultados. Nessa etapa foram adicionados novos atributos a cada instância do conjunto de treinamento. Os novos atributos foram gerados a partir dos componentes de frequência, obtidos com a FFT do sinal.

Tabela 15: Resultado geral de erros e acertos nos testes realizados com RNA e árvore de decisão.

Conjunto de Treinamento	Erros	Acertos
RNA - \tilde{N} Segmentado $_{V_{itro}}$	24,00%	76,00%
RNA - \tilde{N} SegmentadoFFT $_{V_{itro}}$	21,25%	78,75%
RNA - SegmentadoFFT $_{V_{itro}}$	9,25%	90,75%
Árvore de decisão - \tilde{N} Segmentado $_{V_{itro}}$	21,50%	78,50%
Árvore de decisão - \tilde{N} SegmentadoFFT $_{V_{itro}}$	20,00%	80,00%
Árvore de decisão - SegmentadoFFT $_{V_{itro}}$	7,50%	92,50%

5.2 RESULTADOS DOS ENSAIOS *In vivo*

No treinamento dos classificadores para os ensaios *in vivo* foi empregada a mesma metodologia dos ensaios *in vitro*. Inicialmente, foi submetido ao treinamento o conjunto com os dados originais (*Segmentado $_{V_{ivo}}$*), segmentados a cada movimento da mandíbula. Para obter um melhor desempenho, foi criado um segundo conjunto de treinamento (*SegmentadoFFT $_{V_{ivo}}$*) utilizando o sinal original juntamente com as componentes de frequência geradas a partir da FFT do sinal original. Ambos os conjuntos de treinamento foram treinados com RNA e árvore de decisão, com as mesmas configurações dos experimentos *in vitro*.

5.2.1 RESULTADOS OBTIDOS COM O USO DE RNA

Assim como nos ensaios *in vitro*, os conjuntos de dados foram treinados com o algoritmo *back-propagation*.

5.2.1.1 RESULTADOS PARA O CONJUNTO DE TREINAMENTO *Segmentado $_{V_{ivo}}$*

O conjunto de treinamento *Segmentado $_{V_{ivo}}$* é composto por 1000 atributos, formado pelos dados originais segmentados a cada mastigação. O resultado pode ser visto na Tabela 16. A rede neural artificial foi treinada até o ciclo 84.

Na Tabela 16 é possível observar que a classificação da classe 1 (*ração*) obteve 100% de acerto. Este resultado deve-se ao fato de o sinal relativo ao comprimento de onda do movimento mastigatório realizado com este alimento ser distinto dos demais. A mesma situação ocorre com a classificação do *feno*, que obteve 99,5% de acerto. Observa-se, na Figura 29(b), que a variação do comprimento de onda associado varia entre 1541,10 nm e 1541,25 nm o que também faz com que este padrão se destaque dos demais. Já a classificação dos dados relacionados ao *azevém* obteve 76,5% de acerto. O *azevém* recém-colhido possui uma textura

Tabela 16: Matriz confusão da RNA com 5 padrões de mastigação para as simulações com o conjunto de treinamento *SegmentadoVivo*.

	1	2	3	4	5
1	200 (100%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)
2	0 (0,00%)	199 (99,50%)	0 (0,00%)	0 (0,00%)	1 (0,50%)
3	16 (8,00%)	2 (1,00%)	153 (76,50%)	10 (5,00%)	19 (9,50%)
4	7 (3,50%)	0 (0,00%)	6 (3,00%)	186 (93,00%)	1 (0,50%)
5	33 (16,50%)	9 (4,50%)	22 (11,00%)	0 (0,00%)	136 (68,00%)

(1) *Ração*; (2) *Feno*; (3) *Azevém*; (4) *Ruminação*; (5) *Ócio*

mais macia, facilitando a mastigação do alimento pelo animal, ou seja, ao pegar pequenas quantidades de alimento, o sinal de mastigação desse material pode apresentar valores muito próximos à *ração*, *ruminação* e até mesmo *ócio*.

A taxa de acerto do classificador para *ruminação* foi de 93%. Durante o período de *ruminação*, o sinal possui comportamento distinto das demais classes. Durante a *ruminação* as mastigações possuem intervalos maiores entre cada evento e, como o animal não aplica grande quantidade de força, o movimento é mais lento. Os movimentos relacionados ao *ócio* resultaram na menor taxa de acerto. Neste caso, mesmo com a ausência de alimento na mandíbula, os movimentos realizados pelo animal produzem sinais próximos a algumas instâncias das classes *ração* e *azevém*. Tais alimentos produzem sinais com menores variações do comprimento de onda.

5.2.1.2 RESULTADOS PARA O CONJUNTO DE TREINAMENTO *SegmentadoFFT_{Vivo}*

Os resultados da classificação obtidos a partir do conjunto de treinamento *SegmentadoFFT_{Vivo}* são apresentados na Tabela 17. Esse conjunto é formado com dados segmentados, com adição da média e das informações relativas ao espectro de frequência do sinal obtidas via FFT. Para esse conjunto de treinamento a rede neural artificial foi treinada até o ciclo 80.

Os resultados obtidos com o conjunto de treinamento *SegmentadoFFT_{Vivo}* apresentou um incremento na taxa de acerto do classificador quando comparado com os resultados obtidos com o classificador treinado com o conjunto *SegmentadoVivo*. Destaca-se que houve

melhoria significativa naquelas classes com menor percentual de acerto tomando como base o treinamento com os dados do conjunto *SegmentadoVivo*. Para as classes *azevém* e *ócio*, mesmo os sinais possuindo variações semelhantes em suas amplitudes, a forma de onda é distinta. A FFT fornece dados adicionais que são capazes de fazer essa diferenciação.

Tabela 17: Matriz confusão da RNA com 5 padrões de mastigação para as simulações com o conjunto de treinamento *SegmentadoFFT_{Vivo}*.

	1	2	3	4	5
1	200 (100%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)
2	0 (0,00%)	197 (98,50%)	0 (0,00%)	0 (0,00%)	3 (1,50%)
3	2 (1,00%)	0 (0,00%)	171 (85,50%)	7 (3,50%)	20 (10,00%)
4	1 (0,50%)	0 (0,00%)	6 (3,00%)	191 (95,50%)	2 (1,00%)
5	3 (1,50%)	4 (2,00%)	18 (9,00%)	1 (0,50%)	174 (87,00%)

(1) Ração; (2) Feno; (3) Azevém; (4) Ruminação; (5) Ócio.

A Tabela 18 exibe as taxas médias de acerto e de erro dos classificadores. Analisando os dados dessa tabela é possível observar a melhora após a adição dos atributos relacionados à frequência do sinal. Outro fator importante é que a segmentação dos sinais a cada movimento mandibular permite que as características do sinal, para cada classe, seja preservada, mesmo com movimentos mastigatórios com durações distintas.

Tabela 18: Resultado geral de erros e acertos nos testes realizados com RNAs.

Conjunto de Treinamento	Erros	Acertos
<i>SegmentadoVivo</i>	12,60%	87,40%
<i>SegmentadoFFT_{Vivo}</i>	6,70%	93,30%

5.2.2 RESULTADOS OBTIDOS COM O USO DE ÁRVORE DE DECISÃO

Para o treinamento dos classificadores nos ensaios *in vivo* foi adotada a mesma metodologia empregada nos ensaios *in vitro*. Nesta seção serão exibidos os resultados para os conjuntos *SegmentadoVivo* e *SegmentadoFFT_{Vivo}*.

5.2.2.1 RESULTADOS PARA O CONJUNTO DE TREINAMENTO *Segmentado*_{Vivo}

Usando o conjunto de treinamento *Segmentado*_{Vivo}, foi gerada uma árvore de decisão composta de 77 vértices. Destes, 39 são vértices terminais. Apenas 38 dos 1000 atributos previsores formaram os vértices decisão. O atributo 831 gerou duas subárvores. A primeira seleciona os atributos com comprimento de onda menores que 1541,11 nm. Com isso, classifica, principalmente, as classes *ruminação* e *ócio*, além de algumas instâncias de *azevém* e *ração*. Na segunda subárvore, foram classificadas todas as instâncias da classe *feno* e algumas instâncias das classes *azevém* e *ração*. A árvore de decisão gerada pode ser visualizada na Figura 37.

As taxas de acerto para cada classe são apresentadas na Tabela 19. A taxa geral de acerto obtida com a árvore de decisão é semelhante à obtida com as RNAs. Porém, os erros ocorreram na classificação de classes distintas. Enquanto *azevém* e *ócio* obtiveram os menores percentuais de acerto com a RNA, com árvore de decisão *ração* e *azevém* possuem as menores taxas de acerto. No caso da *ração*, o maior erro de classificação ocorreu classificando-a como *azevém*, devido a valores de comprimento de onda semelhantes em algumas amostras. Instâncias de *azevém* também foram classificadas incorretamente como *ração*. Também houve erros relacionados à classe *feno*, pois quando o animal manipulava apenas folhas de *feno* ou quantidades menores de alimento, o sinal de mastigação desse alimento gerava comprimento de onda semelhante aos casos que o animal manipulava a parte mais rígida do *azevém*.

Tabela 19: Matriz de confusão para resultados obtidos através do algoritmo C4.5 utilizando o conjunto de treinamento *Segmentado*_{Vivo}.

	1	2	3	4	5
1	164 (82,00%)	5 (2,50%)	24 (12,00%)	7 (3,50%)	0 (0,00%)
2	2 (1,00%)	182 (91,00%)	14 (7,00%)	1 (0,50%)	1 (0,50%)
3	24 (12,00%)	19 (9,50%)	151 (75,50%)	1 (0,50%)	5 (2,50%)
4	7 (3,50%)	0 (0,00%)	0 (0,00%)	193 (96,50%)	0 (0,00%)
5	5 (2,50%)	0 (0,00%)	4 (2,00%)	1 (0,50%)	190 (95,00%)

(1) *Ração*; (2) *Feno*; (3) *Azevém*; (4) *Ruminação*; (5) *Ócio*

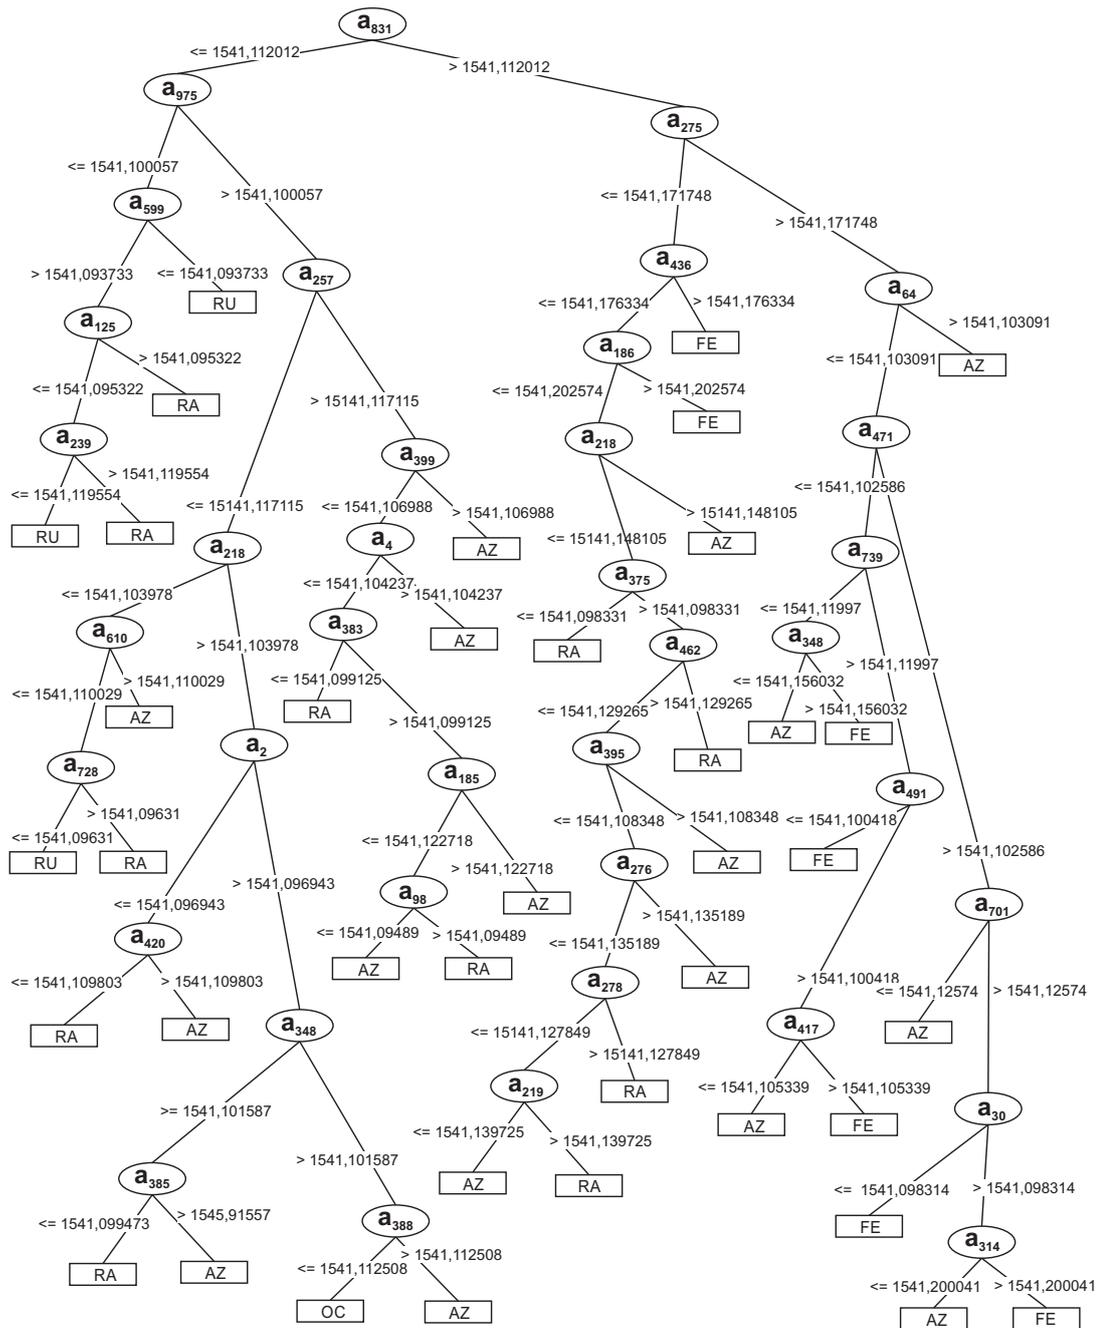


Figura 37: Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento *SegmentadoVivo*.

RA = ração; FE = feno; AZ = azevém; RU = ruminação; OC = ócio.

Fonte: Autoria própria.

5.2.2.2 RESULTADOS PARA O CONJUNTO DE TREINAMENTO *SegmentadoFFT_{Vivo}*

A Figura 38 representa a árvore de decisão gerada a partir do conjunto de treinamento *SegmentadoFFT_{Vivo}*. A árvore de decisão gerada é composta por um total de 83 vértices, sendo 42 vértices terminais e 41 vértices decisão. O atributo 1002 obteve a maior razão do

ganho de informação e dividiu a árvore em duas subárvores. A primeira classificou todas as instâncias da classe *ócio*. Esse atributo refere-se a informações obtidas com a introdução do espectro de frequência. A segunda subárvore possui vértices de decisão compostos por atributos relativos ao sinal original bem como atributos relativos a informações oriundas da FFT. Dentre as subdivisões da árvore de decisão, também pode ser destacada a subárvore formada pelo atributo 1001, que contém a média do sinal, classificando a maior parte dos atributos da classe *ração*.

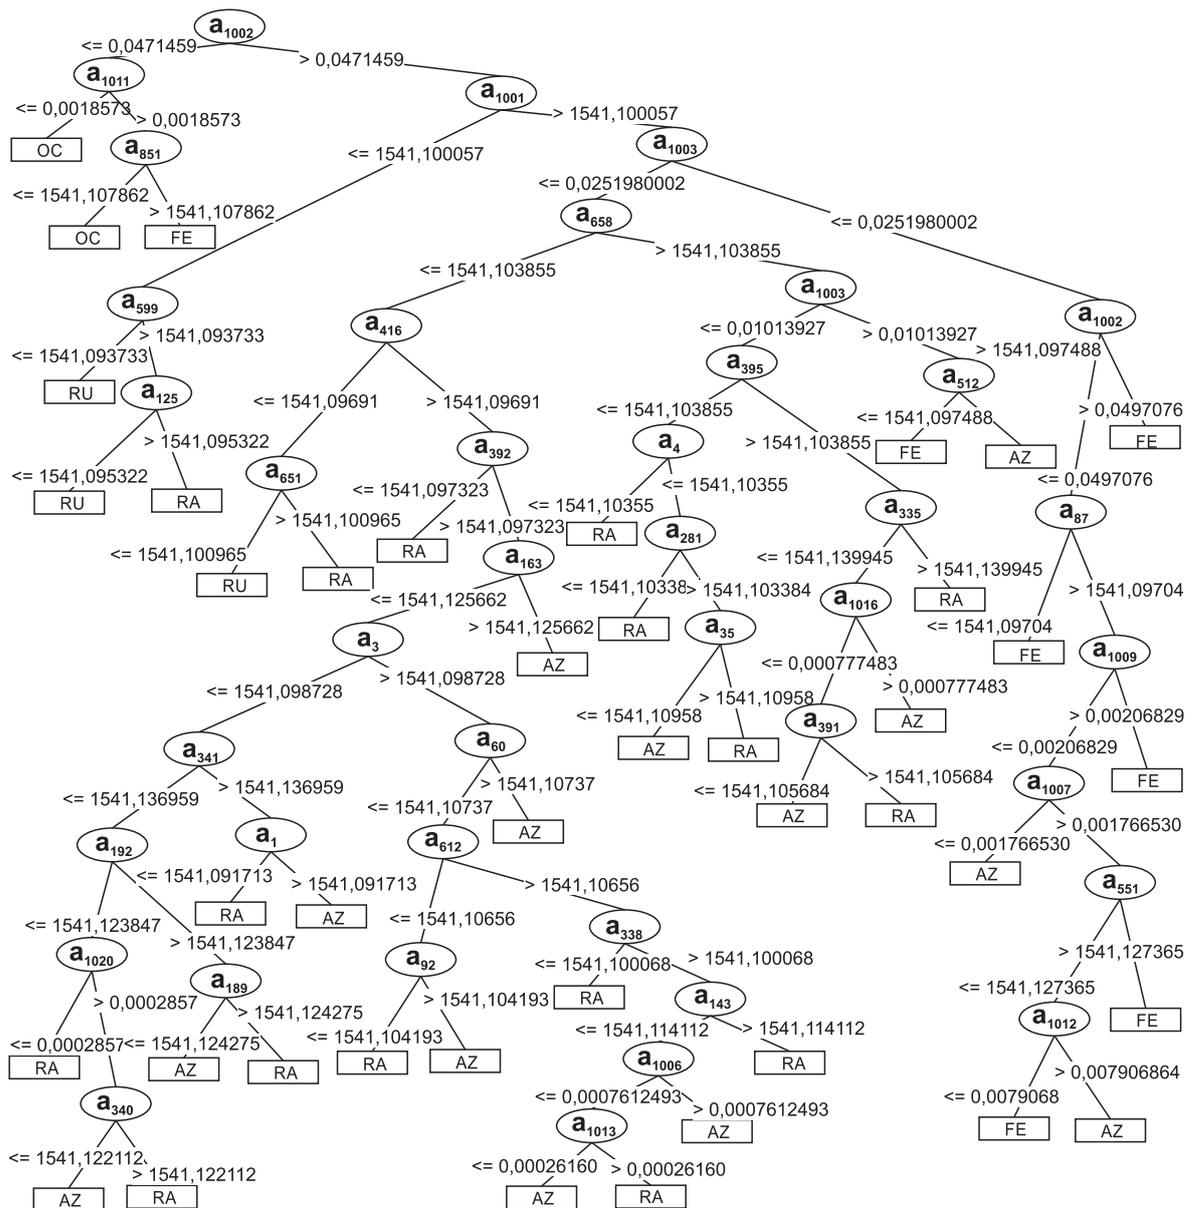


Figura 38: Árvore de decisão gerada com o algoritmo C4.5 utilizando o conjunto de treinamento *SegmentadoFFT_{vivo}*.

RA = *ração*; FE = *feno*; AZ = *azevém*; RU = *ruminação*; OC = *ócio*.

Fonte: Autoria própria.

Observando a árvore de decisão da Figura 38 o primeiro vértice de decisão, formado pelo atributo a_{1002} corresponde à frequência fundamental do sinal. Esse vértice é responsável por dividir a classe *ócio* das demais classes. A frequência fundamental da classe *ócio* é de 1,54 Hz. Portanto, todas as instâncias associadas à classe *ócio* são classificadas próximas ao vértice de decisão inicial. Outro importante vértice de decisão é formado pelo atributo a_{1001} , o qual corresponde ao nível CC do sinal. Por meio desse atributo são classificadas as instâncias da classe *ruminação*. Essa classe possui os menores valores para o nível CC quando comparada com as classes *ração*, *feno* e *azevém*. Entretanto, a classe *ócio* apresenta os menores valores para o nível CC do sinal. Porém o atributo a_{1002} classifica todas as instâncias dessa classe. O atributo a_{1003} que corresponde à segunda componente harmônica do sinal divide a árvore principal em duas subárvores. Uma subárvore é responsável por classificar as classes *feno* e *azevém*. Os vértices pertencentes à essa subárvore estão associados as informações oriundas das componentes de frequência do sinal. A segunda subárvore iniciando no atributo a_{1003} classifica as classes *ração* e *azevém*. Nas subárvores a partir desse vértice, grande parte dos vértices de decisão estão associados aos atributos provenientes do sinal original.

A Tabela 20 apresenta a matriz de confusão do classificador obtido com o conjunto de treinamento *SegmentadoFFT_{Vivo}*. O classificador apresentou maior taxa de acerto para as classes *ruminação* e *ócio*. Essas classes possuem valores de comprimento de onda e formato de onda distinto das demais. As classes *ração* e *azevém* apresentaram a menor taxa de acerto. As variações nos valores de comprimento de onda desses alimentos possuem valores próximos em algumas amostras de mastigação. Para a *ração* a variação é de, aproximadamente, 0.048 nm enquanto para o *azevém* é de aproximadamente 0.060 nm. Também observa-se que algumas amostras dessas classes possuem forma de onda semelhante, ocasionando a classificação incorreta de algumas instâncias.

A taxa de acerto obtida para os classificados gerados com árvore de decisão está exibida na Tabela 21. Os resultados obtidos com a árvore de decisão nos testes *in vivo* foram superiores aos obtidos nos ensaios *in vitro*, pois no ambiente real foi possível observar que os movimentos mandibulares do animal se mostram distintos tanto na força quanto no intervalo de tempo aplicado durante a mastigação de cada material. A força aplicada pelo animal ao mastigar o *feno* foi maior quando comparado aos demais alimentos. Isso ocorreu devido as características do alimento, o qual possui um teor menor que água tornando o alimento mais rígido. Já a *ruminação* é composta por um bolo pastoso, apresentando menor dureza comparado com o *feno*, o que resultou em uma menor quantidade de força aplicada pelo animal. Essas características permitiram a melhora nos resultados obtidos com os classificadores, pois cada material apresentou características distintas durante os movimentos de mastigação.

Tabela 20: Matriz de confusão do conjunto de treinamento *SegmentadoFFT_{Vivo}* usando o algoritmo C4.5.

	1	2	3	4	5
1	172 (86,00%)	0 (0,00%)	24 (12,00%)	4 (2,00%)	0 (0,00%)
2	4 (2,00%)	196 (98,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)
3	24 (12,00%)	4 (2,00%)	172 (86,00%)	0 (0,00%)	0 (0,00%)
4	0 (0,00%)	0 (0,00%)	0 (0,00%)	200 (100%)	0 (0,00%)
5	0 (0,00%)	0 (0,00%)	0 (0,00%)	0 (0,00%)	200 (100%)

(1) *Ração*; (2) *Feno*; (3) *Azevém*; (4) *Ruminação*; (5) *Ócio*.

Tabela 21: Resultado geral de erros e acertos nos testes realizados com árvore de decisão.

Conjunto de Treinamento	Erros	Acertos
Dados segmentados - <i>Segmentado_{Vivo}</i>	12,00%	88,00%
Dados segmentados e FFT - <i>SegmentadoFFT_{Vivo}</i>	6,00%	94,00%

5.3 RESULTADOS GERAIS PARA O EXPERIMENTO *In vivo*

A Tabela 22 apresenta um resumo dos resultados com a RNA e a árvore de decisão para o ensaio *in vivo*. Como pode ser observado na tabela, as técnicas de aprendizagem de máquina produziram resultados semelhantes quando treinadas com o mesmo conjunto de dados. O fator que impactou de maneira mais relevante nos resultados foi a etapa de pré-processamento, na qual foram adicionados novos atributos a cada instância do conjunto de treinamento. Os novos atributos foram gerados a partir dos componentes de frequência, obtidos com a FFT do sinal.

Tabela 22: Resultado geral de erros e acertos nos testes realizados com RNA e árvore de decisão.

Conjunto de Treinamento	Erros	Acertos
RNA - Conjunto de dados <i>Segmentado_{Vivo}</i>	12,60%	87,40%
RNA - Conjunto de dados <i>SegmentadoFFT_{Vivo}</i>	6,70%	93,30%
Árvore de decisão - Conjunto de dados <i>Segmentado_{Vivo}</i>	12,00%	88,00%
Árvore de decisão - Conjunto de dados <i>SegmentadoFFT_{Vivo}</i>	6,00%	94,00%

Para avaliar se as duas técnicas utilizadas apresentam diferenças estatísticas foi realizado o teste *T-Student* (FANG et al., 1990). O teste foi aplicado com base nos resultados

obtidos nos testes *in vitro* e *in vivo*. O *P*-valor resultante foi 0.373364. Isso significa que os algoritmos não apresentam diferenças estatísticas relevantes com um nível de significância $p < 0.05$.

5.4 CONSIDERAÇÕES FINAIS

Os resultados obtidos permitem concluir que ambas as técnicas utilizadas são capazes de gerar regras aptas a classificação dos dados. Todavia, o algoritmo C4.5 de árvore de decisão obteve um desempenho superior ao obtido com o uso de RNA treinada com o algoritmo *back-propagation*. Outro ponto a favor do algoritmo de árvore de decisão é a representação simbólica do classificador, que permite uma compreensão mais clara das regras geradas. Além dos resultados apresentados nesse capítulo, também foram realizados testes com outros algoritmos de aprendizagem de máquina, os quais são exibidos no Apêndice C.

Os conjuntos de treinamento construídos permitiram gerar classificadores com características distintas, que melhoraram com a adição dos valores da FFT do sinal. Outra melhoria no desempenho do classificador foi obtida com a segmentação do sinal definindo, assim, o início e o fim do movimento de mastigação.

O uso de conjuntos de treinamento formados pelos sinais segmentados, juntamente com a FFT do sinal, permitiu que sinais com valores médios similares, mas com formas de onda distintas, pudessem ser discernidos pelo classificador. Dessa forma, este trabalho evidenciou que a etapa de pré-processamento dos dados é importante para a melhoria do desempenho de classificadores.

Além disso, após realizados os testes com a RNA e a árvore de decisão foram desenvolvidas ferramentas para automatizar o processo de aquisição e classificação dos dados, as quais são apresentadas no Apêndice B. As ferramentas computacionais desenvolvidas para as etapas de aquisição, pré-processamento, treinamento e classificação dos dados, devem auxiliar os pesquisadores no processo de avaliação dos resultados, eliminando a etapa manual no momento do pré-processamento e classificação dos dados.

No capítulo 6 serão apresentadas as considerações finais sobre o trabalho e também os trabalhos futuros para o avanço dos resultados obtidos.

6 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentada uma abordagem que faz uso de técnicas de aprendizagem de máquina para classificação de padrões envolvidos no processo de ingestão de alimentos por ruminantes. Os dados utilizados são obtidos através de extensometria ótica pelo uso de sensores baseados em redes de Bragg.

Durante o desenvolvimento do trabalho verificou-se que a aplicação de sensores FBG para coleta de dados relacionados à nutrição de ruminantes é promissor, permitindo a identificação dos principais eventos envolvidos no processo de ingestão de alimentos por ruminantes. O sensor é biocompatível e provê boa sensibilidade ao mesmo tempo em que é imune a interferências eletromagnéticas.

Na etapa de pré-processamento, os dados obtidos pelos sensores FBG foram particionados de forma a definir cada movimento de abertura e fechamento da mandíbula, tanto no experimento *in vitro* quanto no *in vivo*. Nessa etapa, também foi utilizada a FFT para análise do sinal no domínio da frequência. Os dados obtidos por meio da FFT em conjunto com os dados segmentados a cada movimento da mandíbula proporcionaram aprimoramentos significativos na extração de características dos sinais de interesse, o que resultou em melhorias na taxa de acerto dos classificadores.

Os resultados obtidos mostraram que as técnicas de RNA e árvore de decisão podem ser utilizadas para gerar classificadores treinados com dados de mastigação de diferentes tipos de materiais. Os classificadores também podem ser úteis para identificar outros eventos relacionados à nutrição animal, como o ócio e ruminção, sendo este último sendo uma fonte importante de dados relacionados à saúde e bem-estar do animal.

Para os ensaios *in vitro*, os classificadores gerados a partir do sinal segmentado a cada movimento da mandíbula, juntamente com os dados da FFT, geraram taxa geral de acerto de 90% com o uso de RNA e 92,5% com uso de árvore de decisão. Já para os ensaios *in vivo*, os testes realizados com RNA resultaram em uma taxa geral de acerto de 93,3% e os testes realizados com árvore de decisão resultaram em 94% de acerto.

A partir dos resultados obtidos durante o pré-processamento e classificação dos dados, ferramentas foram desenvolvidas para automatizar essas etapas. As ferramentas são apresentadas no Apêndice B. A ferramenta utilizada para aquisição dos dados recebe os dados do interrogador ótico, realiza o pré-processamento dos dados e gera os arquivos para classificação. Já a ferramenta de classificação faz a leitura dos arquivos gerados pela ferramenta anterior e os classifica de acordo com o evento realizado ou alimento consumido pelo animal.

As ferramentas desenvolvidas permitem a contagem individual de cada evento de mastigação. O tempo de pastejo realizado pelo animal também é computado, bem como o alimento que o animal está consumindo durante esse período. Outro importante dado que pode ser analisado pelos pesquisadores é o tempo de repouso do animal (ócio), utilizado para avaliar o intervalo de tempo entre a atividade de pastejo e a ruminação.

O tempo de ruminação também é classificado pelo *software*, bem como o número de mastigações realizadas durante esse período. O processo de ruminação está fortemente relacionado com os tipos de plantas forrageiras utilizadas na alimentação do animal, as quais podem aumentar ou diminuir o tempo de ruminação. Como o consumo de alimento e o processo de ruminação possuem forte influência no ganho de peso e bem-estar de ruminantes, são necessárias informações sobre esses eventos, as quais podem ser obtidas por meio do uso de sensores FBG e a aplicação de técnicas de aprendizagem de máquina. Dessa maneira, as ferramentas desenvolvidas podem trazer informações importantes sobre o processo ingestivo de ruminantes aos profissionais das áreas de zootecnia, veterinária e agronomia. Os pesquisadores das áreas de engenharia elétrica e computação também podem se beneficiar com as ferramentas, uma vez que as etapas de aquisição dos dados, pré-processamento e treinamento dos classificadores serão realizadas de maneira automatizada.

Mesmo que os resultados obtidos sejam encorajadores, estudos complementares podem ser realizados para enriquecer os resultados e novos recursos podem ser implementados nas ferramentas desenvolvidas. Como trabalhos futuros, novos ensaios podem ser realizados visando identificar outros tipos de plantas forrageiras ou alimentos empregados na nutrição de ruminantes. Outra questão a ser analisada sob a ótica de manejo, é a identificação da quantidade de matéria seca consumida pelo animal. Isso poderia ser calculado utilizando-se de informações relacionadas ao tempo de pastejo e quantidade de material consumida durante esse tempo (LACA; WALLISDEVRIES, 2000).

Outro fator que pode ser observado é o desempenho do sensor ao longo de um período maior de tempo, para que possam ser identificadas possíveis alterações nos valores de comprimento de onda durante o crescimento do animal. Como a placa de titânio foi

fixada na mandíbula do animal, o crescimento ósseo do animal pode influenciar nos valores de comprimento de onda coletados. Então, esses valores poderiam ser ajustados no *software* com o objetivo de monitorar o animal por um período maior de tempo. O uso de sensoriamento sem fio também traria benefícios em futuras pesquisas, possibilitando aquisição de dados do animal durante o pastejo no campo sem a necessidade da ligação de um cabo entre o interrogador e o computador que recebe os dados. Ademais, o aprimoramento dos sensores bem como o desenvolvimento de sistemas computacionais especializados são oportunidades de novos estudos.

6.1 PUBLICAÇÕES

Este trabalho contribuiu com o estado da arte nas seguintes publicações:

PEGORINI, Vinicius; RIBEIRO, Richardson; SILVA, Jean Carlos Cardozo da; ASSMANN, Tangriani Simioni; PITTA, Christiano Santos Rocha; CARDOSO, Rafael. **Aprendizagem de máquina aplicada na classificação de padrões de mastigação de ruminantes**. XX Congresso Brasileiro de Automática - CBA 2014. p. 1034-1041.

KARAM, Leandro Zen; PEGORINI, Vinicius; PITTA, Christiano Santos Rocha; ASSMANN, Tangriani Simioni; CARDOSO, Rafael; KALINOWSKI, Hypolito José; Silva, Jean Carlos Cardozo da. **Ex Vivo Determination of Chewing Patterns Using FBG and Artificial Neural Networks**. 23rd International Conference on Optical Fibre Sensors - OFS-23, 2014, Santander. Proceedings of SPIE. Bellingham WA, USA: Society of Photo-Optical Instrumentation Engineers (SPIE), 2014. v. 9157. p. 91573Z-1-91573Z-4.

PEGORINI, Vinicius; KARAM, Leandro Zen; PITTA, Christiano Santos Rocha; RIBEIRO, Richardson; ASSMANN, Tangriani Simioni; Jean Carlos Cardozo da Silva; BERTOTTI, Fábio Luiz; KALINOWSKI, Hypolito José; CARDOSO, Rafael. **In vivo determination of chewing patterns using FBG and Artificial Neural Networks**. In: 24th International Conference on Optical Fibre Sensors, 2015, Curitiba. Proceedings of SPIE, edited by Hypolito José Kalinowski, José Luís Fabris, Wojtek J. Bock. Bellingham WA, USA: Society of Photo-Optical Instrumentation Engineers (SPIE), 2015. v. 9634. p. 963427-1-963427-4. (Publicado).

PEGORINI, Vinicius; KARAM, Leandro Zen; PITTA, Christiano Santos Rocha; DI RENZO, André Biffe; CARDOSO, Rafael; Jean Carlos Cardozo da Silva; KALINOWSKI, Hypolito José; RIBEIRO, Richardson; BERTOTTI, Fábio Luiz; ASSMANN, Tangriani Simioni. **Machine Learning Techniques Applied in the Classification of Ruminant**

Chewing Pattern Using FBG Sensors. In: Simpósio Brasileiro de Automação Inteligente - SBAI 2015, 2015, Natal-RN. Anais do SBAI 2015, 2015. v. único. p. 1-5.

KARAM, Leandro Zen; KALINOWSKI, A.; PEGORINI, Vinicius; PITTA, Christiano Santos Rocha; ASSMANN, Tangriani Simioni; RIBEIRO, Richardson; BERTOTTI, Fábio Luiz; CARDOSO, Rafael; KALINOWSKI, Hypolito José; Silva, Jean Carlos Cardozo da. ***In Vivo Analysis of Bone Strain using Fiber Bragg Grating Sensor and Decision Tree Algorithm in Bovine during Masticatory Movements.*** In: 2015 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference - IMOC 2015, 2015, Porto de Galinhas-PE.

PEGORINI, Vinicius; KARAM, Leandro Zen; PITTA, Christiano Santos Rocha; CARDOSO, Rafael; RIBEIRO, Richardson; ASSMANN, Tangriani Simioni; BERTOTTI, Fábio Luiz; KALINOWSKI, Hypolito José; Silva, Jean Carlos Cardozo da. **Pattern classification of ingestive behaviour in ruminants using FBG sensors and machine learning.** Sensors Basel. (Aceito para publicação).

REFERÊNCIAS

- ABUSHAGUR, A. et al. Advances in bio-tactile sensors for minimally invasive surgery using the fibre bragg grating force sensor technique: A survey. **Sensors**, MDPI AG, v. 14, n. 4, p. 6633–6665, 2014.
- ADVICE, U. S. **IGER Behaviour Analysis System**. abril 2014. Disponível em: <<http://www.ultrasoundadvice.co.uk/index.php/grazing-behaviour/grec3-recorder>>.
- AHA, D.; KIBLER, D. Instance-based learning algorithms. **Machine Learning**, v. 6, p. 37–66, 1991.
- AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. **Machine Learning**, v. 6, p. 37–66, 1991.
- AL-FAKIH, E.; OSMAN, N. A. A.; ADIKAN, F. R. M. The use of fiber bragg grating sensors in biomechanics and rehabilitation applications: The state-of-the-art and ongoing research topics. **Sensors**, MDPI AG, v. 12, n. 12, p. 12890–12926, 2012.
- ALPAYDIN, E. **Introduction to Machine Learning**. Cambridge - MA, England: MIT Press, 2004.
- AMIN, A.; SINGH, S. Recognition of hand-printed chinese characters using decision trees/machine learning c4.5 system. **Pattern Analysis and Applications**, Springer Science + Business Media, v. 1, n. 2, p. 130–141, 1998.
- ATTOH-OKINE, N. O. Analysis of learning rate and momentum term in backpropagation neural network algorithm trained to predict pavement performance. **Advances in Engineering Software**, Elsevier BV, v. 30, n. 4, p. 291–302, 1999.
- AZAR, A. T.; EL-METWALLY, S. M. Decision tree classifiers for automated medical diagnosis. **Neural computing and applications**, v. 23, p. 2387 –2403, 2013.
- BARRETO, F. M. **Esofagostomia Experimental em Caprinos, com Cânula Definitiva e Removível**. Dissertação (Mestrado) — Universidade Federal do Piauí, 2007.
- BERCHIELLI, T. T.; PIRES, A. V.; OLIVEIRA, S. G. de. **Nutrição de Ruminantes**. [S.l.]: Funep, 2006.
- BREIMAN, L. Bagging predictors. **Machine Learning**, Springer Science + Business Media, v. 24, n. 2, p. 123–140, 1996. ISSN 0885-6125.
- BREIMAN, L. Random forests. **Machine Learning**, Springer Science + Business Media, v. 45, n. 1, p. 5–32, 2001. ISSN 0885-6125.
- BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, Springer Science + Business Media, v. 2, n. 2, p. 121–167, 1998. ISSN 1384-5810.

CARVALHO, L. et al. Application of bragg grating sensors in dental biomechanics. **The Journal of Strain Analysis for Engineering Design**, v. 41, n. 6, p. 411–416, jan 2006.

CARVALHO, P.; PRACHE, S.; DAMASCENO, J. O processo de pastejo: desafios da procura e apreensão da forragem pelo herbívoro. **Sociedade Brasileira de Zootecnia**, v. 36, p. 253–268, 1999.

CARVALHO, P. C. F. et al. Do bocado ao pastoreio de precisão: Compreendendo a interface planta-animal para explorar a multi-funcionalidade das pastagens. **Revista Brasileira de Zootecnia**, v. 38, p. 109–122, 2009.

CHAMBERS, A. R. M.; HODGSON, J.; MILNE, J. A. The development and use of equipment for the automatic recording of ingestive behaviour in sheep and cattle. **Grass Forage Science**, v. 36, p. 97–105, 1981.

CHAMPION, R. A.; RUTTER, S. M.; DELAGARDE, R. Recent developments with the iger behaviour recorder. **Proceedings of the Ninth European Intake Workshop**, p. 31–34, 1998.

CHARNIAK, E. Bayesian networks without tears. **Artificial Intelligence Magazine**, v. 12, p. 50–63, 1991.

CHO, J. H.; KURUP, P. U. Decision tree approach for classification and dimensionality reduction of electronic noise data. **Sensors and Actuators, B: Chemical**, v. 160, p. 542–548, 2011.

CLAPHAM, W. M. et al. Acoustic monitoring system to quantify ingestive behavior of free-grazing cattle. **Computers and Electronics in Agriculture**, v. 76, p. 96–104, 2011.

COHEN, W. W. Fast effective rule induction. In: **Twelfth International Conference on Machine Learning**. [S.l.]: Morgan Kaufmann, 1995. p. 115–123.

COOLEY, J. W.; TUKEY, J. W. An algorithm for the machine calculation of complex fourier series. **Mathematics of Computation**, American Mathematical Society, v. 19, n. 90, p. 297–301, 1965.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, p. 273–297, 1995.

COWAN, J. D. Neural networks: The early days. In: KAUFMANN, M. (Ed.). **NIPS**. San Mateo, CA: [s.n.], 1990. v. 2, p. 828–842.

DESWYSEN, A. G. et al. Nycterohemeral eating and ruminating patterns in heifers fed grass or corn silage: analysis by finite fourier transform. **Journal of animal science**, v. 71, p. 2739–2747, 1993.

DIOSDADO, J. A. V. et al. Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. **Animal Biotelemetry**, Springer Science + Business Media, v. 3, n. 1, 2015.

DOVE, H.; MAYES, R. W. The use of plant wax alkanes as marker substances in studies of the nutritional herbivores: a review. **Australian Journal of Agricultural Research**, v. 42, n. 6, p. 913–952, 1991.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2. ed. [S.l.]: Wiley-Interscience, 2000.

ESPOSITO, F. et al. A comparative analysis of methods for pruning decision trees. **IEEE Trans. Pattern Anal. Machine Intell.**, Institute of Electrical & Electronics Engineers (IEEE), v. 19, n. 5, p. 476–493, May 1997. ISSN 0162-8828.

FANG, K.; KOTZ, S.; NG, K. **Symmetric multivariate and related distributions**. [S.l.]: Chapman and Hall, 1990. (Monographs on statistics and applied probability). ISBN 9780412314308.

FENG, Y. et al. Ozone concentration forecast method based on genetic algorithm optimized back propagation neural networks and support vector machine data classification. **Atmospheric environment**, v. 45, p. 1979–1985, 2011.

FISCHER, V. et al. Padrões da distribuição nictemeral do comportamento ingestivo de vacas leiteiras, ao início e ao final da lactação, alimentadas com dieta à base de silagem de milho. **Revista Brasileira de Zootecnia.**, FapUNIFESP (SciELO), v. 31, n. 5, p. 2129–2138, 2002.

FISCHER, V. et al. Aplicação de probabilidades de transição de estado dependentes do tempo na análise quantitativa do comportamento ingestivo de ovinos: Parte ii. **Revista Brasileira de Zootecnia.**, FapUNIFESP (SciELO), v. 29, n. 6, p. 1821–1831, 2000. ISSN 1806-9290.

FISCHLER, M.; FIRSCHEIN, O. **Intelligence: the eye, the brain, and the computer**. [S.l.]: Addison-Wesley, 1987.

FREUND, Y.; SCHAPIRE, R. E. Experiments with a new boosting algorithm. In: SAITTA, L. (Ed.). **Proceedings of the Thirteenth International Conference on Machine Learning (ICML 1996)**. [S.l.]: Morgan Kaufmann, 1996. p. 148–156. ISBN 1-55860-419-7.

FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian network classifiers. **Machine Learning**, Springer Science + Business Media, v. 29, n. 2/3, p. 131–163, 1997. ISSN 0885-6125.

GALLI, J. R. et al. Acoustic monitoring of chewing and intake of fresh and dry forages in steers. **Anim. Feed Sci. Technol.**, v. 128, p. 14–30, 2006.

GRAY, R. M. **Entropy and Information Theory**. New York, NY, USA: Springer-Verlag New York, Inc., 1990.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

HAYKIN, S.; VEEN, B. V. **Signals and systems**. [S.l.]: Wiley, 1999.

HBM. **DAQ Data Acquisition System and Measuring Amplifier - HBM**. abril 2014. Disponível em: <<http://www.hbm.com/en/menu/products/measurement-electronics-software/specialized-data-acquisition-systems/opto-electrical-interrogators/si-di/>>.

HEBB, D. O. **The organization of Behavior: A Neuropsychological Theory**. New York: Wiley, 1949.

HODGSON, J. **Grazing Management: Science Into Practice**. [S.l.]: Longman Scientific & Technical, 1990. (Lha Series).

HOPFIELD, J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences of the United States of America**, v. 79, p. 2554–2558, 1982.

JOCHIMS, F. et al. Comportamento ingestivo e consumo de forragem por cordeiras em pastagem de milheto recebendo ou não suplemento. **Revista Brasileira de Zootecnia**, v. 39, p. 572–581, 2010.

JUNGUO, H.; GUOMOA, Z.; XIAOJUNA, X. Using an improved back propagation neural network to study spatial distribution of sunshine illumination from sensor network data. **Ecological Modelling**, v. 266, p. 86–96, 2013.

KAMPHUIS, C. et al. Detection of clinical mastitis with sensor data from automatic milking systems is improved by using decision-tree induction. **Journal of Dairy Science**, American Dairy Science Association, v. 93, n. 8, p. 3616–3627, 2010.

KHANDANI, A. E.; KIM, A. J.; LO, A. W. Consumer credit-risk models via machine-learning algorithms. **Journal of Banking & Finance**, Elsevier BV, v. 34, n. 11, p. 2767–2787, Nov 2010.

KIM, H. Theory and practice of decision tree induction. **Omega**, Elsevier BV, v. 23, n. 6, p. 637–652, Dec 1995. ISSN 0305-0483.

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995. (IJCAI'95), p. 1137–1143.

KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, p. 59–69, 1982.

KUAN, C.-M.; WHITE, H. Artificial neural networks: an econometric perspective. **Econometric Reviews**, Informa UK Limited, v. 13, n. 1, p. 1–91, Jan 1994. ISSN 1532-4168.

LACA, E. A.; UNGAR, E. D.; DEMMENT, M. W. Mechanisms of handling time and intake rate of a large mammalian grazer. **Applied Animal Behaviour Science**, v. 39, p. 3–19, 1994.

LACA, E. A. et al. An integrated methodology for studying short-term grazing behavior of cattle. **Grass Forage Science**, v. 47, p. 81–90, 1992.

LACA, E. A.; WALLISDEVRIES, M. F. Acoustic measurement of intake and grazing behaviour of cattle. **Grass and Forage Science**, Blackwell Science Ltd, v. 55, n. 2, p. 97–104, 2000.

LI, S.; ZHOU, M.; YANG, Y. Broken wires diagnosis method numerical simulation based on smart cable structure. **Photonic Sensors**, Springer Science + Business Media, v. 4, n. 4, p. 366–372, 2014.

LIM, T.-S.; LOH, W.-Y.; SHIH, Y.-S. A comparison of prediction accuracy, complexity, and training time of thirty-three old and new classification algorithms. **Machine Learning**, Kluwer Academic Publishers, v. 40, n. 3, p. 203–228, 2000.

- LUO, P. et al. Structural damage detection based on a fiber bragg grating sensing array and a back propagation neural network: An experimental study. **Structural Health Monitoring**, SAGE Publications, v. 9, n. 1, p. 5–11, 2010.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115–133, 1943.
- MEZZALIRA, J. C. et al. Aspectos metodológicos do comportamento ingestivo de bovinos em pastejo. **Revista Brasileira de Zootecnia**, v. 40, p. 1114–1120, 2011.
- MICHALSKI, S. R.; CARBONELL, G. J.; MITCHELL, M. T. **Machine Learning an Artificial Intelligence Approach Volume II**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1986.
- MIELOSZYK, M. et al. Application of fibre Bragg grating sensors for structural health monitoring of an adaptive wing. **Smart Materials and Structures**, IOP Publishing, v. 20, n. 12, p. 125014, 2011.
- MILONE, D. H. et al. Computational method for segmentation and classification of ingestive sounds in sheep. **Computers and Electronics in Agriculture**, v. 65, p. 228–237, 2009.
- MISHRA, A. et al. Evaluation of an active optical sensor for detection of huanglongbing (hlb) disease. **Biosystems Engineering**, Elsevier BV, v. 110, n. 3, p. 302–309, 2011.
- MITCHELL, T. M. **Machine Learning**. 1. ed. New York, NY, USA: McGraw-Hill, Inc., 1997.
- MOHANTY, A. K. et al. Texture-based features for classification of mammograms using decision tree. **Neural Computing and Applications**, v. 23, p. 1011–1017, 2013.
- OTHONOS, A.; KALLI, K. **Fiber Bragg Gratings: Fundamentals and Applications in Telecommunications and Sensing**. [S.l.]: Artech House, 1999. (Artech House optoelectronics library).
- PANOPOULOU, A. et al. Experimental modal analysis and dynamic strain fiber bragg gratings for structural health monitoring of composite antenna sub-reflector. **CEAS Space Journal**, Springer Science + Business Media, v. 5, n. 1-2, p. 57–73, 2013.
- PLATT, J. Fast training of support vector machines using sequential minimal optimization. In: SCHOELKOPF, B.; BURGESS, C.; SMOLA, A. (Ed.). **Advances in Kernel Methods - Support Vector Learning**. [S.l.]: MIT Press, 1998.
- QUINLAN, J. R. Discovering rules by induction from large collections of examples. In: MICHIE, D. (Ed.). **Expert Systems in the Micro-Electronic Age**. Edinburgh: Edinburgh University Press, 1979. p. 168–201.
- QUINLAN, J. R. Induction of decision trees. **Machine Learning**, v. 1, p. 81–106, 1986.
- QUINLAN, J. R. Simplifying decision trees. **Int. J. Man-Mach. Stud.**, Academic Press Ltd., London, UK, UK, v. 27, n. 3, p. 221–234, set. 1987.
- QUINLAN, J. R. **C4.5: Programs for machine learning**. [S.l.]: Morgan Kaufmann, 1993.

- REFENES, A. N.; ZAPRANIS, A.; FRANCIS, G. Stock performance modeling using neural networks: A comparative study with regression models. **Neural Networks**, Elsevier BV, v. 7, n. 2, p. 375–388, Jan 1994.
- ROBERT, B. et al. Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle. **Computers and Electronics in Agriculture**, Elsevier BV, v. 67, n. 1-2, p. 80–84, 2009.
- ROCHESTER, N. et al. Tests on a cell assembly theory of the action of the brain, using a large digital computer. **IEEE Transactions on Information Theory**, v. 2, p. 80–93, 1956.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, p. 386–408, 1958.
- RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel distributed processing: Explorations in the microstructure of cognition**. Cambridge, MA: MIT Press, 1986.
- RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. [S.l.]: CAMPUS-Elsevier, 2004.
- RUTTER, S. M. Graze: A program to analyze recordings of the jaw movements of ruminants. **Behavior Research Methods, Instruments, & Computers**, v. 32, p. 86–92, 2000.
- RUTTER, S. M.; CHAMPION, R. A.; PENNING, P. D. An automatic system to record foraging behaviour in free-ranging ruminants. **Applied Animal Behaviour Science**, v. 54, p. 185–195, 1997.
- SANGKATSANEE, P.; WATTANAPONGSAKORN, N.; CHARNSRIPINYO, C. Practical real-time intrusion detection using machine learning approaches. **Computer Communications**, Elsevier BV, v. 34, n. 18, p. 2227–2235, Dec 2011. ISSN 0140-3664.
- SANTOS, N. L. **Avaliação do Campim-Tanzânia manejado com diferentes IAF residuais sob lotação rotacionada por cabras BOER x SAANEN**. Dissertação (Mestrado) — Unesp, Jaboticabal - São Paulo - Brasil, 2009.
- SILVA, C. J. A. et al. Preferência de caprinos em pastejo: Efeito da altura dos dosséis das forrageiras aruana e hemária. **Revista Ciência Animal Brasileira**, v. 10, p. 698–710, 2009.
- SKOWRONSKI, M. D.; HARRIS, J. G. Acoustic detection and classification of microchiroptera using machine learning: Lessons learned from automatic speech recognition. **The Journal of the Acoustical Society of America**, Acoustical Society of America (ASA), v. 119, n. 3, p. 1817, 2006.
- SOEST, P. J. V. **Nutritional Ecology of the Ruminant**. [S.l.]: Comstock Pub., 1994. (A Comstock Bk).
- SUTTON, R. S.; BARTO, A. G. **Introduction to Reinforcement Learning**. 1st. ed. Cambridge, MA, USA: MIT Press, 1998.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. [S.l.]: Elsevier Science, 2008. ISBN 9780080949123.
- TRINDADE, J. K. da. **Comportamento e Consumo de Forragem de Bovinos de Corte em Pastagem Natural Complexa**. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, 2011.

UNGAR, E. D. Ingestive behavior. **Int: Hodgson, J; J. Illius, A. W. (Ed.) The Ecology of management of grazing systems.**, p. 185–218, 1996.

UNGAR, E. D.; RUTTER, S. M. Classifying cattle jaw movements: comparing inger behavior recorder and acoustic techniques. **Appl. Anim. Behav. Sci.**, v. 98, p. 11–27, 2006.

WEKA. **Weka**. 11 2014. Disponível em: <<http://www.cs.waikato.ac.nz>>.

WIDROW, B. Generalization and information storage in networks of adaline neurons. **Self-Organizing Systems**, p. 435–461, 1962.

WOSNIACK, C. et al. Determination of chewing patterns in goats using fiber bragg gratings. **Conference proceedings: OFS 22**, v. 8421, p. 84214F, 2012.

APÊNDICE A – Exemplo de cálculo da razão do ganho de informação

Neste Apêndice será apresentado o cálculo do valor da razão do ganho de informação do algoritmo C4.5. Serão utilizados os dados da Tabela 23, a qual foi trazida do Capítulo 2 a fim permitir ao leitor a consulta mais rápida ao conjunto de dados.

Tabela 23: Conjunto de instâncias de treinamento

valor	idade	salário	conta	empréstimo (Classe)
médio	sênior	baixo	sim	não
médio	sênior	baixo	não	não
baixo	sênior	baixo	sim	sim
alto	média	baixo	sim	sim
alto	jovem	alto	sim	sim
alto	jovem	alto	não	não
baixo	jovem	alto	não	sim
médio	média	baixo	sim	não
médio	jovem	alto	sim	sim
alto	média	alto	sim	sim
médio	média	alto	não	sim
baixo	media	baixo	não	sim
baixo	sênior	alto	sim	sim
alto	média	baixo	não	não

Os dados da Tabela 23 formam o conjunto de dados D . Esse conjunto possui 14 instâncias (exemplos), sendo 9 pertencentes à classe sim e 5 à classe não. A entropia para o conjunto D é calculada de acordo com

$$E(D) = -(9/14) \log_2(9/14) - (5/14) \log_2(5/14) = 0,940.$$

Para o cálculo do ganho de informação do atributo valor (a_1) é necessário calcular a entropia para cada um de seus possíveis valores:

$$E(a_1, \text{baixo}) = -(4/4) \log_2(4/4) - (0/4) \log_2(0/4) = 0;$$

$$E(a_1, \text{medio}) = -(2/5) \log_2(2/5) - (3/5) \log_2(3/5) = 0,971;$$

$$E(a_1, \text{alto}) = -(3/5) \log_2(3/5) - (2/5) \log_2(0/5) = 0,971.$$

O cálculo do ganho de informação para o atributo valor é

$$G(D, a_1) = 0,940 - ((4/14) \cdot 0 + (5/14) \cdot 0,971 + (5/14) \cdot 0,971) = 0,246.$$

Para os demais atributos o cálculo do ganho de informação é dado por:

$$G(D, a_2) = 0,940 - ((4/14) \cdot 1 + (5/14) \cdot 0,971 + (5/14) \cdot 0,722) = 0,049;$$

$$G(D, a_3) = 0,940 - ((7/14) \cdot 0,592 + (7/14) \cdot 0,985) = 0,151;$$

$$G(D, a_4) = 0,940 - ((8/14) \cdot 0,811 + (6/14) \cdot 1) = 0,047.$$

O atributo que obteve o maior valor para o ganho de informação foi o atributo valor, com 0.246, sendo designado como vértice raiz, no caso do algoritmo ID3.

Para calcular a razão do ganho de informação, utilizado no algoritmo C4.5, é necessário calcular a informação para cada atributo:

$$INF(D, a_1) = -4/14 \cdot \log_2(4/14) - 5/14 \cdot \log_2(5/14) - 5/14 \cdot \log_2(5/14) = 1,577;$$

$$INF(D, a_2) = -4/14 \cdot \log_2(4/14) - 5/14 \cdot \log_2(5/14) - 5/14 \cdot \log_2(5/14) = 1,577;$$

$$INF(D, a_3) = -7/14 \cdot \log_2(7/14) - 7/14 \cdot \log_2(7/14) = 1;$$

$$INF(D, a_4) = -8/14 \cdot \log_2(8/14) - 6/14 \cdot \log_2(6/14) = 0,985.$$

A razão do ganho de informação para cada um dos atributos é dada por:

$$RG(D, a_1) = 0,246/1,577 = 0,156;$$

$$RG(D, a_2) = 0,049/1,577 = 0,029;$$

$$RG(D, a_3) = 0,151/1 = 0,151;$$

$$RG(D, a_4) = 0,047/0,985 = 0,047.$$

APÊNDICE B – Automatização dos processos de aquisição e classificação dos dados

Neste apêndice serão apresentadas as ferramentas desenvolvidas para aquisição e classificação dos dados relacionados ao comportamento ingestivo de ruminantes.

Durante o processo de aquisição dos dados foi necessária a gravação em vídeo, a qual foi utilizada para rotular os dados de acordo com o evento ou alimento consumido. Para realizar a segmentação correta dos dados a cada movimento de mastigação, o vídeo foi analisado na intenção de gerar um conjunto de treinamento com cada instância rotulada corretamente. Assim, para otimizar a etapa manual de rotulação dos dados e auxiliar no processo de classificação dos dados foram desenvolvidas ferramentas para automatizar a aquisição dos dados e realizar a classificação dos mesmos usando algoritmos de aprendizagem de máquina.

A primeira ferramenta foi desenvolvida em paralelo a este trabalho. Essa ferramenta é responsável pelas etapas de aquisição e pré-processamento dos dados. A tela principal dessa ferramenta é mostrada na Figura 39. Na etapa de aquisição dos dados, a ferramenta recebe os dados do interrogador ótico. Após a aquisição, esses dados são submetidos a etapa de pré-processamento que, seguindo a metodologia descrita neste trabalho, segmenta cada movimento de mastigação, faz o cálculo da FFT e gera arquivos que são utilizados pela ferramenta de treinamento e classificação dos dados. São gerados dois tipos de arquivo: o primeiro é utilizado durante a etapa de treinamento do classificador, o qual contém as instâncias rotuladas de acordo com a respectiva classe, ou seja, um conjunto de treinamento; o segundo arquivo é gerado durante a etapa de classificação, contendo apenas uma instância, a qual não estará rotulada.

Na Figura 39 (a) é exibido o reconhecimento do sensor pelo *software*. Após esse reconhecimento é necessário informar o diretório onde os dados serão salvos, informação apresentada na Figura 39 (b). Na primeira etapa será realizada a aquisição de dados para o treinamento do classificador. Portanto, deve ser selecionado o modo de operação "Treinamento" na Figura 39 (c). Nessa etapa, também deverá ser informado o rótulo associado à classe da qual serão coletados os movimentos de mastigação. Esse dado é informado na caixa de texto apresentada na Figura 39 (d). Para o funcionamento correto do conjunto de ferramentas, durante a etapa de treinamento do classificador, deve ser monitorado apenas um alimento ou evento a

cada ensaio. Juntamente com o alimento ou evento monitorado serão rotulados os períodos de ócio.

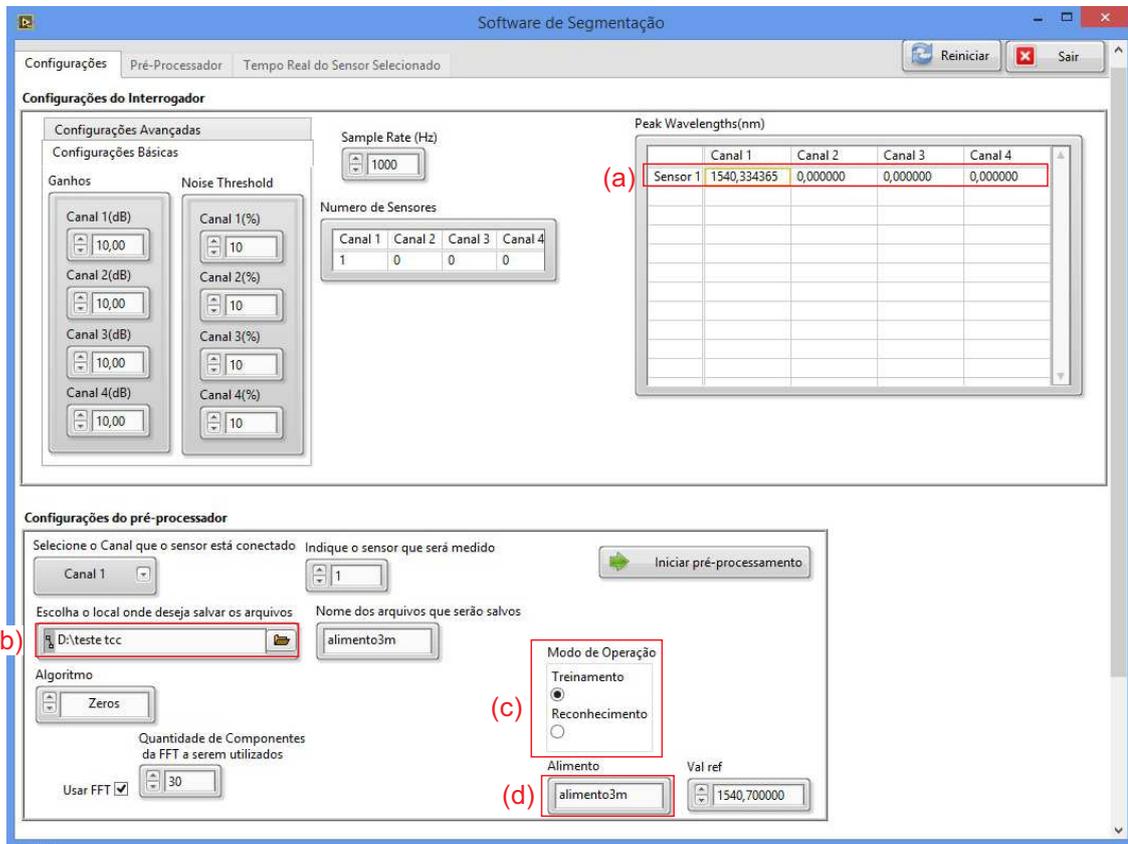


Figura 39: Software de aquisição e pré-processamento dos dados. (a) reconhecimento do sensor; (b) diretório onde serão salvos os arquivos gerados; (c) modo de operação; (d) rótulo da classe que está sendo monitorada.

Fonte: Autoria própria.

Na etapa em que são gerados os arquivos para classificação é necessário o reconhecimento do sensor pelo *software*. Então, deve-se informar o diretório onde os dados serão salvos, conforme mostra a Figura 39 (b). Esse diretório também será utilizado pela ferramenta de classificação de padrões. Em seguida, deve-se selecionar a opção "Reconhecimento" na Figura 39 (c). Desta forma, a ferramenta irá gerar, sequencialmente, um arquivo para cada movimento de mastigação realizado pelo animal.

A segunda ferramenta é empregada nas etapas de treinamento e classificação dos dados. Na etapa de treinamento, a ferramenta deve receber um arquivo contendo todas as instâncias rotuladas de acordo com o evento ou alimento ingerido pelo animal. A tela de treinamento é apresentada na Figura 40. Como saída, é gerado um arquivo contendo o conjunto de regras obtidos após o treinamento do classificador. Esse mesmo arquivo deverá ser importado pelo *software* durante a etapa de classificação dos dados.

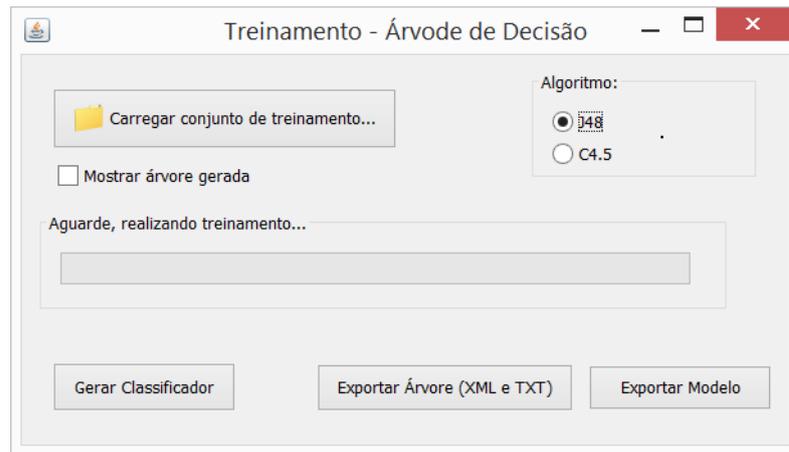


Figura 40: Tela de treinamento do classificador.

Fonte: Autoria própria.

Na etapa de classificação, após importar o arquivo contendo as regras, a ferramenta recebe os arquivos gerados durante a aquisição e pré-processamento. Cada arquivo gerado contém uma instância que representa um movimento de mastigação. Assim, cada instância é classificada pelo conjunto de regras de acordo com o alimento ou evento realizado. Além da classificação dos dados, o *software* exibe a taxa de mastigação, o número de eventos realizados pelo animal e o tempo relacionado a cada classe. Essas funcionalidades são ilustradas na Figura 41. A figura contendo o gráfico pode ser exportada no formato "PNG" (*Portable Network Graphics*) e os dados de tempo de mastigação e número de eventos podem ser exportados no formato "CSV" (*Comma-Separated Values*), para posterior uso pelos pesquisadores da área de nutrição animal.

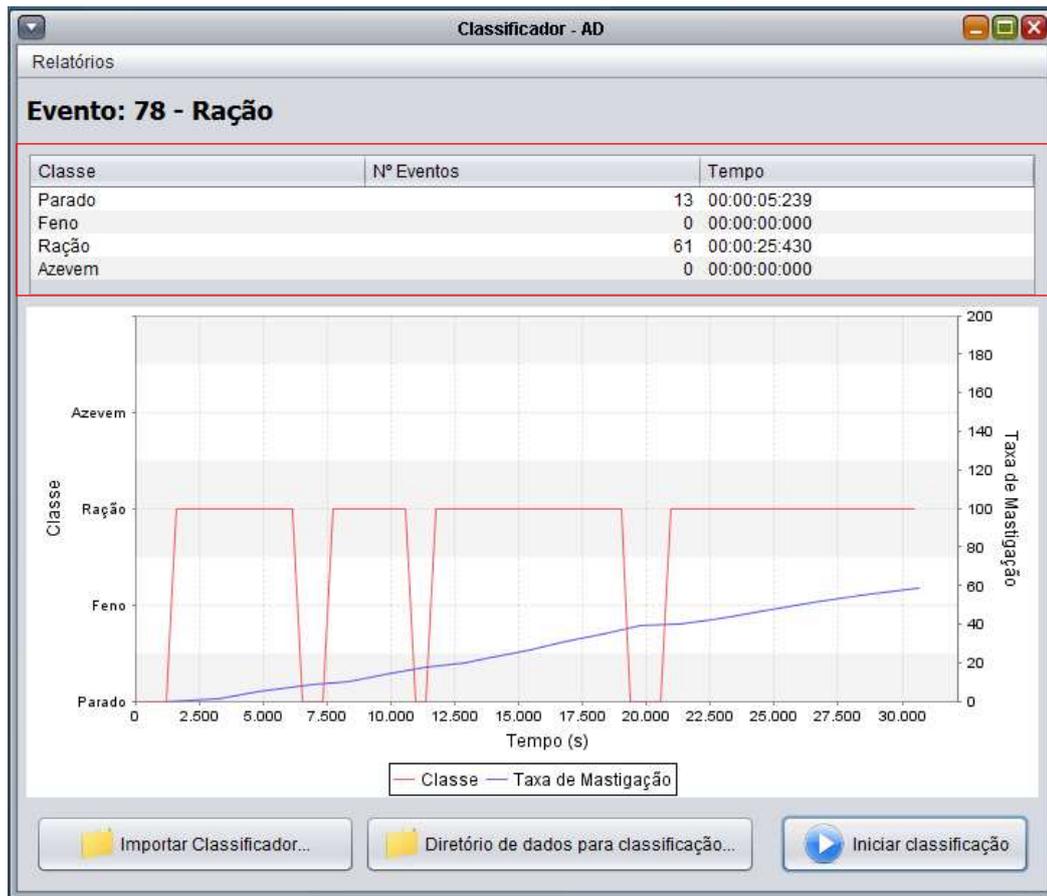


Figura 41: Tela de classificação de novos dados.

Fonte: Autoria própria.

As etapas necessárias para a classificação dos dados podem ser visualizadas no diagrama de atividade da Figura 42. Inicialmente, os dados adquiridos pelo interrogador ótico são transmitidos à ferramenta de aquisição. Então os dados passam pela etapa de pré-processamento. Nessa etapa, realiza-se a segmentação dos dados a cada movimento de mastigação e o cálculo da FFT do sinal. O resultado da etapa de pré-processamento é uma instância não rotulada contendo um movimento de mastigação, a qual é armazenada em um arquivo em formato de texto e salva em disco. A ferramenta de classificação faz a leitura desse arquivo e classifica a instância de acordo com o conjunto de regras gerado durante a etapa de treinamento. Por fim, os dados relacionados a cada movimento de mastigação são armazenados na ferramenta, e no final do processamento dos dados essas informações podem ser exportadas pelos pesquisadores.

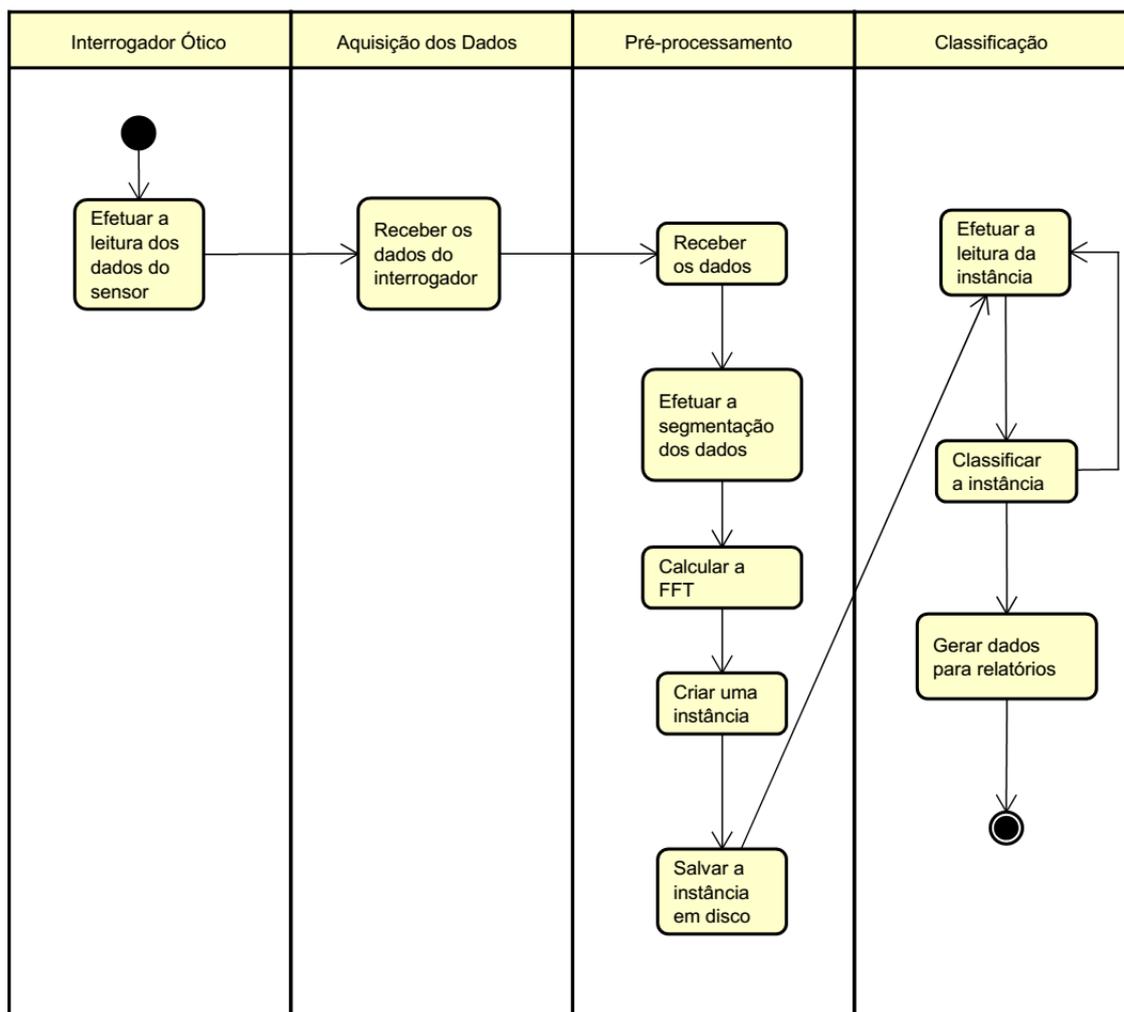


Figura 42: Diagrama de atividade para as etapas de aquisição, pré-processamento e classificação dos dados.

Fonte: Autoria própria.

APÊNDICE C – Resultados dos algoritmos de aprendizagem de máquina

Neste apêndice serão apresentados os resultados do treinamento de diferentes algoritmos de aprendizagem de máquina implementados na ferramenta Weka (WEKA, 2014). Os testes foram realizados com o conjunto de dados *SegmentadoFFT_{vivo}*, o qual foi descrito no Capítulo 4.

Na Tabela 24 é possível observar as acurácias obtidas após o treinamento de diferentes algoritmos de aprendizagem de máquina. Segundo o teste estatístico T-Student (FANG et al., 1990), os algoritmos de Florestas Randômicas (BREIMAN, 2001), Redes Bayesianas (FRIEDMAN et al., 1997), SMO (PLATT, 1998), *K-nearest neighbours* (KNN) (AHA; KIBLER, 1991), Boosting (FREUND; SCHAPIRE, 1996), Bagging (BREIMAN, 1996) e JRip (COHEN, 1995) não apresentaram diferença estatística significativa quando comparados com os algoritmos J48 e Back-propagation, entretanto estes dois algoritmos apresentaram acurácia maior quando comparados aos demais. Já o algoritmo *Support vector machine* (SVM) (BURGES, 1998) apresentou desempenho inferior aos demais algoritmos.

Tabela 24: Resultados de acurácia dos algoritmos de aprendizagem de máquina sobre o conjunto de dados *SegmentadoFFT_{vivo}*.

	Acurácia
J48	94%
Back-propagation	93,3%
Randon Forests	90,49%
Naive Bayes	87,67%
SVM	66,83%
SMO	91,80%
KNN	91,20%
Boost	90,99%
Bagging	90,73%
JRIP	87,94%

ANEXO A – Parecer da comissão de ética no uso de animais (ceua)



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



PROJETO DE PESQUISA / AULA PRÁTICA

Título:	Medição e Classificação de Padrões de Mastigação de Ruminantes Utilizando Fibra Ótica e Inteligência Artificial
Área Temática:	Exatas, da Terra e Engenharias
Pesquisador / Professor:	Jean Carlos Cardozo da Silva
Instituição:	UTFPR
Versão:	002

PARECER CONSUBSTANCIADO DA CEUA	Protocolo nº 2013-009
Título: Medição e Classificação de Padrões de Mastigação de Ruminantes Utilizando Fibra Ótica e Inteligência Artificial	
Pesquisador/Professor: Jean Carlos Cardozo da Silva	
Área temática: Exatas, da Terra e Engenharias	
Instituição: UTFPR - Pato Branco e Palmas	
Financiamento: Não mencionado	
Apresentação do Projeto: Os pesquisadores envolvidos nesta proposta têm interesses distintos, mas correlacionados. Os pesquisadores da área de processamento de sinais pretendem estudar diferentes técnicas de processamento para determinar parâmetros que diferenciem os cinco processos envolvidos no pastejo (bocado, manipulação do alimento, mastigação, ruminação e densidade do alimento). A pesquisadora ligada à agronomia pretende, a partir dos sinais identificados, verificar a taxa de ingestão alimentar do animal e, assim, melhor gerenciar ambientes pastoris. Há ainda o pesquisador envolvido neste projeto, da área de instrumentação ótica, que tem interesse de conhecer as forças mandibulares envolvidas na mastigação com o objetivo de melhor compreender o processo de	



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



transferência de forças para futuros projetos de próteses biomédicas implantáveis.
<p>Objetivo:</p> <p>O objetivo geral deste projeto é aplicar redes de Bragg para medir forças mandibulares envolvidas no processo de pastejo de animais. Os sinais resultantes desta instrumentação serão utilizados por pesquisadores de diferentes áreas de conhecimento, Ciências Agrárias, Engenharia Elétrica e Biomecânica, sendo a interpretação destes sinais fundamentais em pesquisas relacionadas à pecuária de precisão e sinais biomecânicos.</p> <ul style="list-style-type: none"> - Determinação de forças e adaptação dos sensores in vivo; - Estudo de técnicas para a análise e processamento de sinais, visando a automação da identificação dos diferentes padrões envolvidos no processo de pastejo, importantes para a pecuária de precisão: bocado, manipulação do alimento, mastigação e ruminção; - Desenvolvimento de procedimentos e instrumentação para avaliar e gerenciar ambientes pastoris.
<p>Avaliação dos Riscos e Benefícios:</p> <p>Há o risco de desconforto por parte do animal com a fixação do aparelho na mandíbula do mesmo.</p>
<p>Comentários e Considerações sobre a Pesquisa / Aula Prática:</p> <p>O projeto tem relevância e trará grandes avanços na pesquisa sobre comportamento ingestivo de animais de produção.</p>
<p>Considerações sobre os Termos de apresentação obrigatória:</p> <p>Todos os termos foram entregues.</p>
<p>Conclusões ou Pendências e Lista de Inadequações:</p> <p>Os pesquisadores atenderam todas as recomendações.</p>
<p>Situação do Parecer:</p> <p>APROVADO</p>
<p>Considerações Finais a Critério da CEUA:</p> <p>Considerando que as pendências/inadequações foram sanadas dentro do prazo de 30 dias, previsto para apresentação das mesmas, somos favoráveis a aprovação do presente projeto.</p>

Dois Vizinhos, 11 de março de 2014.

Assinado por:

Patricia Franchi de Freitas