

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE ELÉTRICA
CURSO DE ENGENHARIA ELÉTRICA

WESLEY JEAN DA SILVA

**ESTUDO DO EMPREGO DE REDES NEURAIS ARTIFICIAIS PARA A
CLASSIFICAÇÃO DE PADRÕES MASTIGATÓRIOS DE CAPRINOS**

TRABALHO DE CONCLUSÃO DE CURSO

PATO BRANCO

2014

WESLEY JEAN DA SILVA

**ESTUDO DO EMPREGO DE REDES NEURAIS ARTIFICIAIS PARA A
CLASSIFICAÇÃO DE PADRÕES MASTIGATÓRIOS DE CAPRINOS**

Trabalho de Conclusão de Curso de graduação, apresentado à disciplina de Trabalho de Conclusão de Curso 2, do Curso de Engenharia Elétrica do Departamento de Engenharia Elétrica – DAELE – da Universidade Tecnológica Federal do Paraná – UTFPR, Câmpus Pato Branco, como requisito parcial para obtenção do título de Engenheiro.

Orientador: Prof. Dr. Rafael Cardoso

Co-orientador: Prof. Dr. Jean Carlos Cardozo da Silva

PATO BRANCO

2014

TERMO DE APROVAÇÃO

O trabalho de Conclusão de Curso intitulado **ESTUDO DO EMPREGO DE REDES NEURAIS ARTIFICIAIS PARA A CLASSIFICAÇÃO DE PADRÕES MASTIGATÓRIOS DE CAPRINOS**, do aluno **WESLEY JEAN DA SILVA** foi considerado **APROVADO** de acordo com a ata da banca examinadora N° **46** de 2014.

Fizeram parte da banca os professores:

Rafael Cardoso

Fabio Luiz Bertotti

Vinicius Pegorini

Tangriani Simioni Assmann

A ATA assinada encontra-se na Coordenação do Curso de Engenharia Elétrica.

Dedico essa grande conquista à minha família pelo imenso apoio proporcionado ao longo da minha vida acadêmica.

AGRADECIMENTOS

À Deus, pela oportunidade de chegar até aqui, mesmo passando por dificuldades durante todo o percurso. Sou grato a todos os professores que tive ao longo da vida, os quais contribuíram de alguma forma em meu crescimento pessoal e intelectual. Agradeço em especial aos meus pais que foram meus professores da vida, uma vez que aprendi e continuo por aprender muito com eles. Desejo registrar minha profunda gratidão ao meu irmão Willian Andrey da Silva, que foi meu companheiro durante todo o curso de Engenharia e com certeza meu braço direito, sempre ajudando em minhas dificuldades neste percurso. Por último, mas não menos importante, gostaria de agradecer à minha namorada e aos meus amigos, que por muitos finais de semana tive que negar convites e deixar de vê-los para me dedicar ainda mais aos estudos para avaliações e desenvolvimento de trabalhos acadêmicos.

O único lugar onde o sucesso vem antes do trabalho é no
dicionário.

(Albert Einstein)

RESUMO

SILVA, Wesley Jean da. Estudo do emprego de Redes Neurais Artificiais para a classificação de padrões mastigatórios de caprinos. 2012. 72 f. Trabalho de Conclusão de Curso – Curso de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Pato Branco, 2012.

Este trabalho de conclusão de curso descreve o uso de Redes Neurais Artificiais para a classificação de padrões mastigatórios de caprinos. Considerou-se os padrões mastigatórios oriundos da mastigação de cinco diferentes elementos: mastigação sem elementos, com duas plasticinas de texturas diferentes, com feno de Tifton e com aveia recém colhida. As informações sobre os padrões foram obtidas através do uso de sensores óticos baseados em redes de Bragg (FBG). Esse sensor monitora as forças biomecânicas envolvidas no processo de mastigação. O interesse dessa abordagem é testar a capacidade das redes neurais classificarem e reconhecerem a presença ou não de diferentes elementos durante a mastigação em uma mandíbula cadavérica de caprino. Utilizou-se uma rede neural, *feedforward*, como treinamento baseado no algoritmo *backpropagation*.

Palavras-chave: Redes Neurais Artificiais, Inteligência Artificial, Classificação de Padrões, Nutrição Animal, Caprinocultura, Comportamento de Ingestão, Pastejo.

ABSTRACT

SILVA, Wesley Jean da. Study the use of neural networks for classification of chew patterns of goats. 2012. 72 f. - Course of Electrical Engineering, Federal Technological University of Paraná. Pato Branco, 2012.

This undergraduate final project describes the use of Artificial Neural Networks for classification of chew patterns of goats. It was considered the chew patterns of five different elements: no material in the mouth, two Plasticines of different textures, hay and oat. Information about patterns were obtained through the use of optical sensors based on fiber Bragg gratings sensors (FBG). This sensor monitors the biomechanical forces involved in chewing process. The interest of this approach is test the ability of neural networks to classify and recognize the presence of different elements during the chewing process of a goat. It was used a feedforward neural network based on the backpropagation algorithm for training.

Keywords: Artificial Neural Networks, Artificial Intelligence, Pattern Classification, Animal Nutrition, Goat Production, Ingestion Behavior, Grazing.

LISTA DE FIGURAS

Figura 1: Modelo de um neurônio artificial.	20
Figura 2: Modelo de Waren McCulloch e Walter Pitts.	20
Figura 3: Neurônio Artificial.	21
Figura 4: RNA multicamada.	24
Figura 5: Caprinos distribuídos nos piquetes, com fraldas.	26
Figura 6: FFotografia da incisão e da cânula de acrílico no esôfago	27
Figura 7: Fotografia mostrando o animal se alimentando com a bolsa coletora	27
Figura 8: Novilha equipada com microfone à frente conectado ao gravador digital. .	28
Figura 9: FFragmentos de registro acústico de: (a) pastejo; (b) ruminação	29
Figura 10: Cabeça cadavérica de caprino utilizada nas simulações de mastigação.	30
Figura 11: Sinal da mastigação durante período de simulação com a Plasticina A ..	31
Figura 12: Sinal da mastigação durante período de simulação com a Plasticina B .	32
Figura 13: Sinal da mastigação durante período de simulação com Aveia	33
Figura 14: Sinal da mastigação durante período de simulação com Feno.....	34
Figura 15: Sinal da mastigação sem massa durante período de simulação	35
Figura 16: Blocos da RNA.	37
Figura 17: Sinal da mastigação adquirida durante 80segundos com plasticinas	38
Figura 18: Mastigação em um intervalo de 5 segundoscom plasticinas	39
Figura 19: Mastigação em um intervalo de 1 segundo com plasticinas	40
Figura 20: Seleção dos vetores de entrada e alvos.	41
Figura 21: Definição da porcentagem destinada à validação e teste.	42
Figura 22: Definição da quantidade de neurônios utilizados na camada oculta.	42
Figura 23: Realização do treinamento; geração da matriz confusão e curvas ROC.	42
Figura 24: Sinal da mastigação adquirida durante 80 segundos com Plasticina A. ..	43
Figura 25: Sinal da mastigação adquirida durante 80 segundos com Plasticina B. ..	44
Figura 26: Sinal da mastigação adquirida durante 80 segundos com Aveia.	44
Figura 27: Sinal da mastigação adquirida durante 80 segundos com Feno.....	44
Figura 28: Sinal da mastigação adquirida durante 80 segundos sem Massa.	45
Figura 29: Mastigação em um intervalo de 5 segundos com Plasticina A.....	45
Figura 30: Mastigação em um intervalo de 5 segundos com Plasticina B.....	45
Figura 31: Mastigação em um intervalo de 5 segundos com Aveia.	46

Figura 32: Mastigação em um intervalo de 5 segundos com Feno de Tifton.	46
Figura 33: Mastigação em um intervalo de 5 segundos sem Massa.....	46
Figura 34: Matriz confusão, resposta da validação, teste e treinamento da RNA.	49
Figura 35: Demonstração da rede neural usada.	49
Figura 36: Matriz confusão, resposta da validação, teste e treinamento – 83,5%. ...	51
Figura 37: Matriz confusão, resposta da validação, teste e treinamento – 68,5%. ...	52
Figura 38: Inicialização da <i>GUIDE</i>	54
Figura 39: Tela inicial do ambiente gráfico.	55
Figura 40: Criação da interface gráfica do usuário.....	55
Figura 41: Parametrização da interface gráfica do usuário.	56
Figura 42: Plotando a matriz confusão.....	57
Figura 43: Plotando a curva ROC.	57
Figura 44: Escolha de entradas para o treinamento da RNA via interface gráfica. ...	58
Figura 45: Visualização do comprimento de onda utilizado como entrada.....	58
Figura 46: Resposta do teste de classificação de padrões via interface gráfica.	59
Figura 47: Resposta do teste de classificação de padrões via interface gráfica.	59
Figura 48: Resposta do teste de classificação de cinco padrões mastigatórios.....	60

LISTA DE SIGLAS E ABREVIATURAS

AIFF	<i>Audio Interchange File Format</i>
cdo	Comprimento de Onda
DAELE	Departamento de Engenharia Elétrica
dB	Decibel
FBG	Rede de Bragg (<i>Fiber Bragg Grating</i>)
FP	Falso Positivo (<i>False Positive</i>)
Hz	Hertz
IA	Inteligência Artificial
IAPAR	Instituto Agrônômico do Paraná
IBGE	Instituto Brasileiro de Geografia e Estatística
ms	Milissegundo
NPRTOOL	Ferramenta Neural de Reconhecimento de Padrões (<i>Neural Pattern Recognition Tool</i>)
ROC	<i>Receiver Operating Characteristic</i>
RNA	Rede Neural Artificial
s	Segundo
TP	Positivo Verdadeiro (<i>True Positive</i>)
UTFPR	Universidade Tecnológica Federal do Paraná
GUI	Interface Gráfica de Usuário (<i>Graphical User Interface</i>)
GUIDE	Ambiente de Desenvolvimento de Interface Gráfica de Usuário (<i>Graphical User Interface Development Environment</i>)

SUMÁRIO

1. INTRODUÇÃO.....	14
1.1 CARACTERIZAÇÃO DO PROBLEMA.....	15
1.2 OBJETIVOS.....	16
1.2.1 Objetivo Geral.....	16
1.2.2 Objetivos específicos.....	17
1.3 ORGANIZAÇÃO DO TRABALHO.....	17
2. REVISÃO LITERÁRIA.....	18
2.1 INTELIGÊNCIA ARTIFICIAL: A REDE NEURAL.....	18
2.2 O QUE É UMA REDE NEURAL?.....	18
2.2.1 Modelo de McCulloch-Pitts.....	20
2.2.2 Modelo Geral de Neurônio.....	21
2.3 PROCESSO DE APRENDIZADO DA RNA.....	22
2.3.1 Aprendizado supervisionado.....	22
2.3.2 Aprendizado não supervisionado.....	23
2.4 O ALGORITMO <i>BACKPROPAGATION</i>	23
3. ESTUDO DO CASO.....	25
3.1 MÉTODOS CONVENCIONAIS JÁ UTILIZADOS.....	25
3.1.1 Análise de ganho de peso.....	26
3.1.2 Análise por fistula esofágica.....	26
3.1.3 Análise pelo método acústico.....	28
4. MATERIAIS E MÉTODOS.....	30
4.1 AQUISIÇÃO DOS SINAIS REFERENTES À MASTIGAÇÃO, ANÁLISE E CLASSIFICAÇÃO.....	30
4.2 USO DE REDE NEURAL ARTIFICIAL PARA A CLASSIFICAÇÃO DOS PADRÕES MASTIGATÓRIOS.....	35
4.2.1 Ferramenta para Reconhecimento de Padrões.....	36

4.2.2 RNA para classificação de dois padrões mastigatórios	37
4.2.3 RNA para classificação de cinco padrões mastigatórios	43
5 APRESENTAÇÃO E ANÁLISE DE RESULTADOS.....	48
5.1 RESULTADOS REFERENTES À RNA PARA CLASSIFICAÇÃO DE DOIS PADRÕES MASTIGATÓRIOS	48
5.2 RESULTADOS REFERENTES À RNA PARA CLASSIFICAÇÃO DE CINCO PADRÕES MASTIGATÓRIOS	50
5.3 ANÁLISE DOS RESULTADOS OBTIDOS.....	53
6 DESENVOLVIMENTO DE UMA INTERFACE GRÁFICA PARA O USUÁRIO ...	54
6.1 DESENVOLVENDO UMA INTERFACE UTILIZANDO A <i>GUIDE</i>	54
7 CONCLUSÕES.....	61
8 REFERÊNCIAS	63
APÊNDICE	66
APÊNDICE B.....	69

1. INTRODUÇÃO

Segundo Agricultura (2013), a caprinocultura é uma das subáreas da zootecnia que vem se destacando no agronegócio brasileiro. A pesquisa realizada por Agricultura (2013) aponta que um dos fatores que influenciaram no desenvolvimento desta ciência foi a mudança dos hábitos alimentícios da população. Segundo a pesquisa, a população passou a se alimentar de carne caprina por se tratar de uma carne mais magra. Desta forma, as vendas brasileiras podem alcançar níveis internacionais, impulsionando o comércio e a criação de caprinos. Com o aquecimento da caprinocultura, os investimentos em pesquisas e experimentos desta área também crescem, contribuindo para o mundo acadêmico e científico.

Conforme Tortorelli *et al.* (2009), a maior parte do rebanho de cabritos no Brasil encontra-se no Nordeste, principalmente nos estados de Pernambuco, Bahia, Piauí e Ceará. Além da carne, também são aproveitados a pele e a lã dos cabritos. Adicionalmente, dos caprinos também se obtém a produção de leite, que, devido ao fato das empresas que trabalham neste ramo serem de pequeno porte, faz com que o volume de leite comercializado seja pequeno quando comparado com outros tipos de produção leiteira.

Para Mezzalira *et al.* (2012), os aspectos mais importantes para a compreensão dos processos envolvidos no pastejo se tratam da avaliação do comportamento ingestivo, consumo de forragem por animais em pastejo e a sua interação com a estrutura do pasto. O consumo de forragem é importante para determinar a qualidade do pasto, além de avaliar o impacto que os animais causam nos ecossistemas pastoris.

De acordo com Carvalho *et al.* (2009), a aplicação dos métodos para avaliar o comportamento e estimar o consumo de forragem por animais durante as pastagens são difíceis, além de serem caros e imprecisos. Novas tecnologias e avanços nos métodos analíticos têm procurado automatizar a forma da coleta, processamento e análise dos dados relativos ao comportamento ingestivo e consumo de forragem por animais em pastejo.

O presente trabalho tem por propósito a elaboração de um estudo para o desenvolvimento e análise de viabilidade de uma ferramenta capaz de auxiliar as

pesquisas envolvendo nutrição de caprinos. Uma vez realizando o estudo para caprinos, o mesmo pode ser expandido para outros mamíferos.

Esta ferramenta visa automatizar todo o processo de determinação e classificação de padrões mastigatórios de caprinos. Os dados a serem analisados serão fornecidos por sensores à fibra ótica fixada junto ao maxilar do animal. Sabendo que tal fibra tem a espessura muito reduzida, será necessária apenas uma microcirurgia, tornando-se um método menos invasivo, não precisando aguardar por uma recuperação do animal. Cabe ressaltar que esta microcirurgia é apenas para a fixação da fibra ótica no maxilar do caprino utilizado como objeto de estudo.

Este trabalho está vinculado com um projeto de pesquisa o qual tem como enfoque a determinação de sinais biomecânicos envolvidos no processo de pastejo de caprinos a partir de sensores à fibra ótica. Destaca-se que o uso de fibra ótica e sua fixação ao maxilar do animal estão fora do escopo deste trabalho, uma vez que este foca apenas no processamento dos dados advindos de tal sistema de instrumentação e aplicação de Inteligência Artificial utilizando as Redes Neurais Artificiais.

1.1 CARACTERIZAÇÃO DO PROBLEMA

De acordo com a pesquisa realizada por Virtual (2013), estudos relacionados à caprinocultura sempre estiveram em ascensão. Geralmente os estudos são relacionados à nutrição animal, que tem como objetivo a análise dos diferentes tipos de pasto em conjunto com as diferentes regiões climáticas do país. Nestes estudos, tenta-se estabelecer uma relação dos benefícios que o pasto pode oferecer para o animal e também a quantidade que o mesmo ingere de matéria seca. Sabendo-se que a lotação de hectares por animal deve ser adequada à cada condição edafo-climática e tipo de pastagem, a principal finalidade destes estudos é determinar a área potencial de bocado de diferentes animais e a massa apreendida durante certo período de pastejo. Com isso, pode-se obter o tempo mínimo para abate dos caprinos com uma boa lotação em hectare por animal e sem a extinção do pasto durante o período de engorda.

De acordo com Assmann, Assmann e Soares (2013) o Brasil apresenta o maior rebanho comercial do mundo, com uma área destinada a criação em torno de 90 milhões de há. Adicionalmente, a produção de carne bovina é a principal atividade agrícola brasileira, sobrepondo-se, inclusive, ao cultivo de soja que possui área de cultivo de, aproximadamente, 27,7 milhões de ha.

Mesmo tendo a pecuária uma cadeia produtiva maior do que a de soja, observa-se que inúmeras instituições têm realizado grandes investimentos em novas tecnologias para o avanço do cultivo de soja no país. Já os investimentos para a área de pecuária de precisão, forrageiras e nutrição animal, não se equiparam, sendo seus valores muito menores do que os dedicados à produção de soja, por exemplo. Assim, estas áreas relacionadas à pecuária carecem de pesquisas inovadoras para o desenvolvimento de tecnologias para a melhoria do processo produtivo.

Neste trabalho, objetiva-se investigar o uso de Redes Neurais Artificiais (RNA), as quais são uma opção para problemas de reconhecimento de padrões, uma vez que segundo Ferreira *et al.* (2005), a utilização da RNA é factível. Este estudo visa verificar qual a eficiência do uso de redes neurais para o problema em questão. Adicionalmente, objetiva-se desenvolver uma interface gráfica para o uso da rede neural para o propósito mencionado.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Este trabalho objetiva o estudo da aplicação de Redes Neurais Artificiais para determinação de padrões de mastigação de caprinos com base em sinais oriundos de sensores à fibra ótica, implantados no maxilar dos caprinos. Posteriormente, deve-se realizar a análise dos resultados do estudo, avaliando a viabilidade do uso das redes neurais para os objetivos de classificação dos padrões mastigatórios.

1.2.2 Objetivos específicos

- Adquirir sinais de uma mandíbula cadavérica referentes às mastigações dos materiais utilizados para as simulações de mastigação;
- Estudar o uso do algoritmo *backpropagation* para o treinamento de Redes Neurais Artificiais (RNAs) para o fim desejado;
- Retrabalhar os sinais adquiridos e os dados levantados de forma adequada a trabalhar com as Redes Neurais Artificiais (RNAs);
- Implementar o código criado para a classificação de padrões;
- Treinar e testar o algoritmo;
- Avaliar o desempenho do algoritmo;
- Desenvolver um *software* em Matlab para implementar o sistema de classificação de padrões;
- Elaborar uma interface gráfica de usuário para o uso da RNA.

1.3 ORGANIZAÇÃO DO TRABALHO

Este trabalho de conclusão de curso está dividido em oito capítulos e dois apêndices, dispostos da seguinte maneira:

No capítulo 2, é exposta uma revisão bibliográfica abordando assuntos sobre a Inteligência Artificial e também sobre Redes Neurais Artificiais e suas aplicações. Em seguida, o capítulo 3 dispõe a respeito dos métodos de estudo e análise do comportamento ingestivo de ruminantes utilizados na atualidade. Na sequência, o capítulo 4 apresenta as metodologias utilizadas na elaboração deste trabalho, demonstrando as formas e ferramentas utilizadas. No capítulo 5 são apresentados os resultados obtidos. Já no capítulo 6 apresentam-se as conclusões finais sobre este trabalho. No capítulo 7 têm-se as referências bibliográficas utilizadas para a elaboração do trabalho. E por fim, nos apêndices estão evidenciados trechos dos códigos criados para a elaboração da rede neural artificial demonstrada neste trabalho.

2. REVISÃO LITERÁRIA

2.1 INTELIGÊNCIA ARTIFICIAL: A REDE NEURAL

Para Júnior (2000), a partir da inteligência artificial pode-se elaborar equipamentos ou máquinas que realizem tarefas mentais do ser humano. Através de *softwares* lógicos ou matemáticos pode-se implementar rotinas através de um computador em equipamentos que possam desenvolver atividades que envolvam sentidos como tato, audição e visão, ou até mesmo capacidades intelectuais como aprendizado de conceitos, raciocínio dedutivo e memória. Os equipamentos que utilizam este tipo de tecnologia podem realizar várias atividades no lugar do homem.

Segundo Júnior (2000), as Redes Neurais Artificiais são a ferramenta mais utilizada na ciência de Inteligência Artificial, pois possuem processadores chamados neurônios, os quais mimetizam o sistema nervoso biológico. As redes neurais são amplamente utilizadas para resolução de várias tarefas, sendo a mais conhecida o reconhecimento de vários tipos de padrões, além de aplicações em controle de sistemas dinâmicos, entre outras.

De acordo com Novais *et al.* (2009) foram os avanços na área da neurobiologia, em especial a descoberta do neurônio, o que tornou possível desenvolver a teoria das redes neurais artificiais, a qual possui como principal unidade de processamento o neurônio artificial.

2.2 O QUE É UMA REDE NEURAL?

De acordo com Haykin (2001), o cérebro é um computador muito mais complexo do que um computador convencional, além de realizar tarefas com uma rapidez surpreendente. Este é o fato que motiva as pesquisas científicas e trabalhos com redes neurais artificiais, pois o cérebro tem habilidade de organizar seus neurônios de forma a realizar processamentos tanto comuns até os mais complexos e em uma velocidade extraordinária.

Para Haykin (2001), esta eficiência do cérebro se dá devido às experiências vividas, visto que o maior aprendizado do cérebro ocorre nos dois primeiros anos de vida. Isto se dá ao fato de que há muitos novos eventos acontecendo neste período, desta forma o ser humano passa pelo aprendizado da fala, interação com outros seres, dentre outros novos acontecimentos, os quais voltarão a se repetir no decorrer de sua existência.

Um neurônio em crescimento ou aperfeiçoamento o torna flexível. Esta flexibilidade permite que o sistema nervoso em crescimento se adapte ao seu meio ambiente. Assim, a flexibilidade é essencial para o funcionamento dos neurônios biológicos como unidades de processamento de informação e também para as redes neurais artificiais. De forma geral, uma rede neural artificial é um equipamento projetado para realizar tarefas complexas de uma forma aproximada a de um cérebro humano. A rede neural artificial é implementada ou simulada por programação em um computador. Para obter resultados satisfatórios, as redes neurais empregam uma interligação sólida de células chamadas de neurônios. Pode-se obter a seguinte definição de uma rede neural vista como uma máquina adaptativa:

"Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

- 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*
 - 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido."*
- (HAYKIN, 2001).

Segundo Haykin (2001), para o processo de aprendizagem de uma rede neural artificial, os pesos sinápticos são modificados até que a resposta desejada seja alcançada. É através dos pesos sinápticos que os neurônios da rede irão classificar um sinal de entrada, como corretamente classificados ou erroneamente classificados. A Figura 1 ilustra as sinapses representadas pelas entradas e pesos sinápticos, somatório e função de ativação. As sinapses são evidenciadas por sinais

de entrada, onde há a multiplicação pelo seu peso sináptico neuronal. Os resultados obtidos são somados e aplicados a uma função de ativação que limita a resposta da rede neural em 0 ou 1.

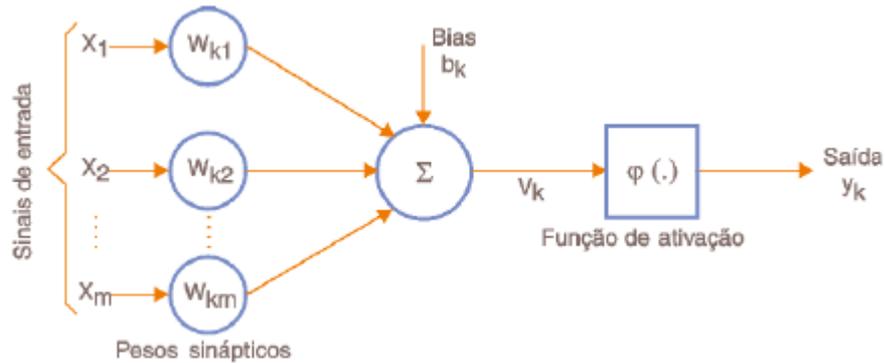


Figura 1: Modelo de um neurônio artificial.
Fonte: Atual (2013).

Segundo Lopes *et al.* (2009), a principal vantagem em utilizar redes neurais artificiais está na sua capacidade de adaptação e aprendizagem. Uma rede neural, cujo treinamento obteve um desempenho satisfatório, é capaz de deduzir a resposta através da experiência quando sinais diferentes dos utilizados no seu treinamento são apresentados na entrada da rede neural.

2.2.1 Modelo de McCulloch-Pitts

Segundo Barreto (1999), McCulloch interpretou o funcionamento do neurônio como sendo um circuito binário, seu modelo binário é demonstrado na Figura 2.

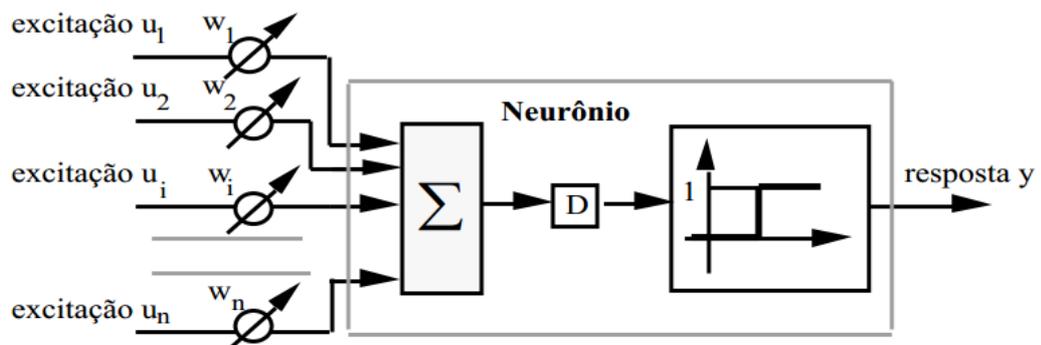


Figura 2: Modelo de Warren McCulloch e Walter Pitts.
Fonte: Barreto (1999).

De acordo com Barreto (1999), o valor do sinal da entrada da RNA sofre um atraso D e serve de argumento para a função de ativação, e na sequência a resposta de saída. Como o modelo é binário, a saída será $[0 \ 1]$, como resposta do neurônio. Além da resposta, neste caso a entrada do neurônio é também binária e as entradas são combinadas por uma soma ponderada, produzindo a entrada efetiva do neurônio (Barreto, 1999):

$$entrada_{efetiva} = \sum_1^n w_i u_i \quad (1)$$

2.2.2 Modelo Geral de Neurônio

Segundo Barreto (1999), o modelo geral de um neurônio artificial, que é amplamente utilizado em trabalhos com aplicações de redes neurais, foi criado a partir do modelo de McCulloch e de Walter Pitts de 1943, este modelo é ilustrado pela Figura 3.

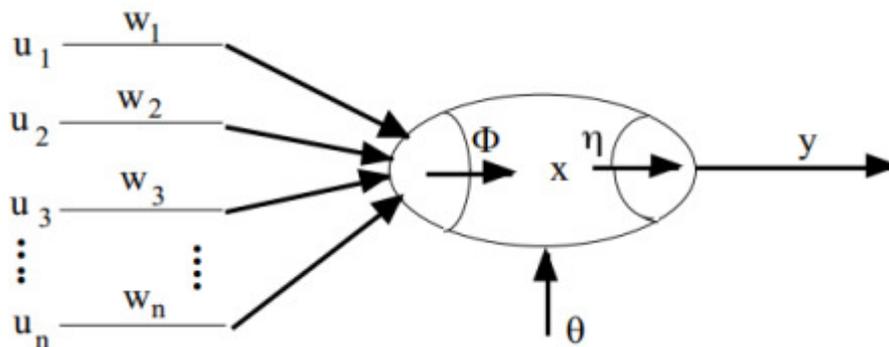


Figura 3: Neurônio Artificial.
Fonte: Barreto (1999).

De acordo com Barreto (1999), no modelo geral do neurônio os sinais das entradas $w_i u_i$ mostrados na Figura 3 são somados pela função ϕ e produzem um estado de ativação do neurônio que através da função η indicará a resposta da rede neural. Um valor auxiliar Θ é geralmente usado para representar uma polarização. As conexões sinápticas e os pesos sinápticos não são considerados no modelo geral de neurônio. Tal modelo demonstra que a resposta do neurônio pode variar entre zero e um valor máximo. Este modelo pode ser representado pelas equações (Barreto, 1999):

$$\frac{dx}{dt} = \phi(x(t), w_i(t), u_i(t), \Theta(t)) \quad (2)$$

$$y(t) = \eta(x(t)) \quad (3)$$

2.3 PROCESSO DE APRENDIZADO DA RNA

Alvarez e Luque (2003) afirmam que a particularidade mais significativa das redes neurais é a capacidade do aprendizado a partir do seu ambiente, obtendo assim um melhor desempenho. Isto só é possível devido ao fato da rede neural possuir a alternativa de ajustar seus pesos sinápticos durante o treinamento. Pode-se dizer que haverá este aprendizado a partir do momento em que a resposta da rede neural for correta e adquirida através de uma generalização da rede neural.

Os algoritmos de aprendizado mais utilizados para modelos de redes neurais são os de aprendizado supervisionado e o de aprendizado não supervisionado. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

2.3.1 Aprendizado supervisionado

Também é chamado de aprendizado com professor. Esta forma de aprendizado se baseia em um conjunto de exemplos de entrada-saída que é apresentada à rede. A partir da entrada, a rede realiza seu processamento e a resposta obtida é comparada com o valor da resposta esperada. Caso os valores não sejam os mesmos, os pesos sinápticos são ajustados buscando um erro mínimo ou aceitável. O algoritmo de aprendizado supervisionado mais utilizado é o *backpropagation* (HAYKIN, 2001).

2.3.2 Aprendizado não supervisionado

Também chamado de aprendizado por esforço, o aprendizado não supervisionado consiste em um sistema onde a rede neural escolhe o valor da resposta através de um sinal de entrada aplicado a partir de regras pré-estabelecidas. O aprendizado não supervisionado por esforço baseia-se no mapeamento dos sinais de entrada e saída através do convívio com o ambiente e experiências adquiridas (HAYKIN, 2001).

2.4 O ALGORITMO *BACKPROPAGATION*

Visto que a elaboração da RNA para classificação de padrões mastigatórios utilizará amostras de dados previamente coletadas e tratadas, o algoritmo utilizado na criação da rede neural artificial será o de aprendizado supervisionado *backpropagation*.

Para Carvalho *et al.* (1998) entre os algoritmos de aprendizado supervisionado, o *backpropagation* se destaca por ser ordenado na correção de erros. Tal algoritmo tem por objetivo obter valores para os pesos sinápticos que reduzam o erro da rede, de forma a encontrar o valor de resposta adequado para cada sinal de entrada.

Segundo Haykin (2001), o algoritmo *backpropagation* utiliza valores de entrada e de saída para realizar o ajuste dos pesos sinápticos dos neurônios, onde a quantidade de vezes necessárias para realizar tais ajustes depende do tipo de treinamento utilizado. Tais treinamentos podem ser por padrão ou por ciclo. No treinamento por padrão a resposta obtida é conferida após a leitura de cada valor ou vetor apresentado. Já no treinamento por ciclo, a resposta obtida é conferida quando todos os valores da matriz de treinamento ou conjunto de vetores de entrada são apresentados à rede. Os ajustes dos pesos sinápticos e a conferência da resposta obtida são realizados até o momento onde o erro da classificação tiver um valor mínimo aceitável ou quando a variação do erro for muito pequena sendo insuficiente para interferir no desempenho da rede neural artificial.

De acordo com Jr. e Costa (2007), uma rede neural pode ter uma ou várias camadas. A topologia utilizada em conjunto com o algoritmo *backpropagation* é a *feedforward* multicamadas, que possui mais de uma camada entre as de entrada e saída, conforme é ilustrado na Figura 4. Redes neurais artificiais multicamadas possuem as chamadas camadas escondidas, que também são chamadas de ocultas. A vantagem das camadas ocultas é a possibilidade de alterar a quantidade de neurônios quando necessário.

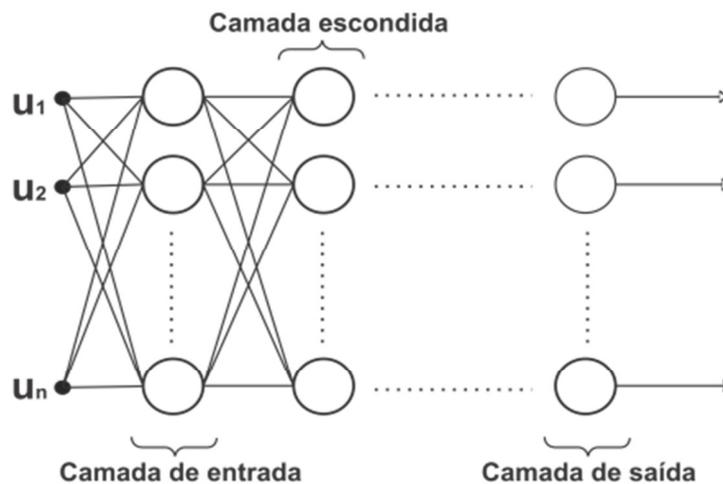


Figura 4: RNA multicamada.
Fonte: Autoria Própria.

Com o algoritmo de aprendizado definido, fica evidente que o algoritmo *backpropagation* se trata da melhor opção para a elaboração da rede neural para o problema proposto, visto que tem como característica principal a sua organização durante a correção dos erros.

Tendo em mente a utilização de inteligência artificial para a classificação de padrões mastigatórios de ruminantes, faz-se necessário conhecer o funcionamento dos métodos utilizados na atualidade, analisando seus pontos fortes e fracos, para que se possa realizar uma ferramenta que supra todas as necessidades nas pesquisas em campo e em laboratório.

3. ESTUDO DO CASO

De acordo com Mezzalira *et al.* (2012), os aspectos mais importantes para a compreensão dos processos envolvidos no pastejo são a avaliação do comportamento ingestivo, o consumo de forragem por animais em pastejo e a sua interação com a estrutura do pasto. O consumo de forragem é importante para determinar a qualidade do pasto, além de avaliar o impacto que os animais causam nos ecossistemas pastoris.

Ainda para Mezzalira *et al.* (2012), a medição do consumo de forragem pelos animais é o item mais difícil de quantificar durante as pesquisas realizadas em pastagens. Os métodos atuais para avaliar o comportamento ingestivo dos animais e estimar o consumo de forragem em pastejo são complexos, caros e imprecisos. Mas, atualmente, o avanço da tecnologia e os investimentos em pesquisas nas áreas de zootecnia e nutrição animal contribuem para os avanços nos métodos analíticos para coleta e análise dos dados relativos ao comportamento ingestivo e consumo de forragem por animais em pastejo.

O estudo do comportamento de ruminantes é fundamental para compreender as relações planta-animal no ambiente pastoril, enquanto que as atividades diárias são basicamente divididas em períodos de pastejo, ruminação e interações sociais.

3.1 MÉTODOS CONVENCIONAIS JÁ UTILIZADOS

Alguns dos métodos convencionais mais utilizados entre os pesquisadores da área da ciência animal são baseados em: análise de ganho de peso durante o pastejo; coleta de alimentos usando fístula esofágica e através do método acústico.

3.1.1 Análise de ganho de peso

O método de análise de ganho de peso consiste basicamente em colocar os animais em piquetes com pastagem onde, segundo Barros *et al.* (2006), os animais são equipados com fraldas geriátricas para reter fezes e urina. Em algumas cabras avaliadas, é colocada uma focinheira para impedir a ingestão de pastagem, a fim de gerar um parâmetro de estimativa de perdas. Os animais são pesados em balança de precisão, colocados no piquete por certo período de tempo, sendo contado o número de bocados nesse período e pesados novamente após o pastejo.

De acordo com Barros *et al.* (2006), quantifica-se a quantidade de massa adquirida pelos animais durante o pastejo através da diferença dos pesos pós-pastejo e pré-pastejo, somada à média das perdas das cabras de focinheira. Desta forma, dividindo o valor da massa ingerida pelo número de bocados medidos, é possível ter uma estimativa da massa adquirida por bocados. A Figura 5 ilustra os animais com as fraldas e focinheiras no momento do pastejo, além de mostrar o momento da pesagem do animal.



Figura 5: Caprinos distribuídos nos piquetes, com fraldas.
Fonte: Santos (2009).

3.1.2 Análise por fistula esofágica

No segundo método é utilizada fístula esofágica que, para Barreto (2007), é uma prática comum e é necessária uma cirurgia nos cabritos por profissionais habilitados. A fístula esofágica é um método que permite coletar os alimentos

ingeridos pelos ruminantes durante o pastejo. Para a realização deste tipo de estudo, deve-se primeiramente encaminhar a pesquisa ao Comitê de Ética, por ser uma cirurgia de risco à vida do animal. Com a liberação da pesquisa pelo Comitê de Ética, os animais são levados a uma clínica veterinária onde é realizada a cirurgia. Na cirurgia, o animal é sedado por anestesia, é feita uma incisão no esôfago e instalada uma cânula conforme ilustrado pela Figura 6, que será responsável pelo desvio do alimento para uma bolsa coletora.

Após a cirurgia, os animais são levados para o centro de pesquisa onde diariamente são observadas as condições da cânula e da fístula, inspeção do comportamento do animal, presença de apetite e sede, capacidade de deglutição e ruminação e exame da ferida cirúrgica. Após a recuperação do animal, ele é solto no pasto voltando à sua rotina normal de pastar no campo, contudo, agora com a bolsa coletora fixada com uma coleira em seu pescoço, com o objetivo de obter amostras das pastagens ingeridas. A figura 7 mostra o animal com a bolsa coletora fixa ao pescoço se alimentando normalmente.



Figura 6: Fotografia da: (a) incisão; (b) colocação da cânula de acrílico no esôfago.
 Fonte: Barreto (2007).



Figura 7: Fotografia mostrando: (a) o animal com a bolsa; (b) se alimentando com a bolsa.
 Fonte: Barreto (2007).

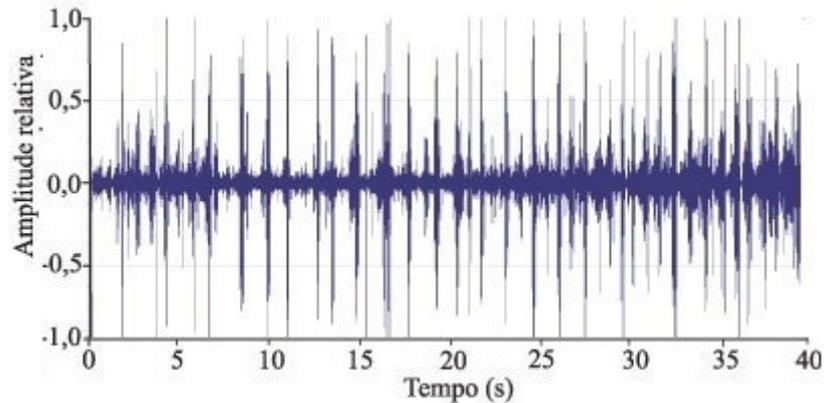
3.1.3 Análise pelo método acústico

O terceiro método mencionado é o método acústico de quantificação do tempo de pastejo e de ruminação. De acordo com Trindade (2011), para se obter registros sonoros os animais são equipados com buçais que permitem sustentar um gravador digital e um microfone. O funcionamento do método consiste em discriminar as atividades dos animais segundo as características acústicas, frequência (Hz), intensidade (dB), duração (s) e intervalos (s). Os animais são instalados em piquetes e equipados com um microfone de lapela fixo ao buçal. O microfone é protegido com um isopor para minimizar ruídos externos, como ilustrado pela Figura 8. Para gravar e armazenar os registros sonoros é utilizado um gravador digital com cartão de memória também fixo ao buçal e protegidos contra umidade.

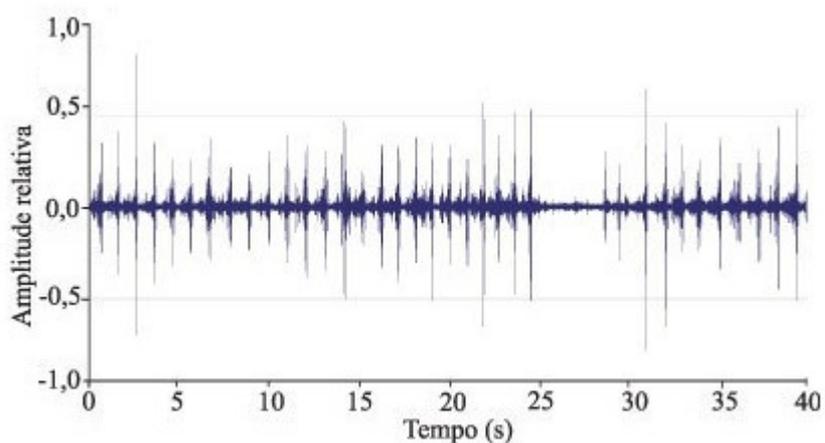
Junto com este processo digital são necessários alguns observadores para acompanhar os movimentos dos animais, identificando os sinais de ruminação, pastejo e outras atividades, quando os mesmos são liberados nos piquetes durante um intervalo de tempo. Ao fim do dia, os registros são transferidos para um computador, convertidos para o formato *.aif* e analisados por um programa de edição de áudio, onde os dados são analisados e identificados através de gráficos como os mostrados na Figura 9, bem como com o conjunto de anotações dos observadores. A partir disso, são estimados os tempos referentes à mastigação e ruminação.



Figura 8: Novilha equipada com microfone à frente conectado ao gravador digital.
Fonte: Trindade (2011).



(a)



(b)

Figura 9: Fragmentos de registro acústico de: (a) pastejo; (b) ruminação.
Fonte: Trindade (2011).

Para Trindade (2011), a maior vantagem da técnica acústica é a precisão com relação ao método visual. Além do mais, o método acústico implica na não necessidade de avaliadores permanentes, observações noturnas e numa estimativa que se julga mais fidedigna, por não incorrer riscos de alteração do comportamento dos animais e nem na subjetividade dos observadores.

Como se pode perceber, os estudos são feitos com base em estimativa de ingestão de matéria seca, tempo de pastejo, taxa de bocado, entre outros indicadores. As formas e ferramentas existentes na atualidade para a realização desse tipo de estudo apresentam alguns fatores negativos, pois envolve, em sua maioria, um procedimento de classificação totalmente manual.

No próximo capítulo é apresentada a metodologia utilizada para a elaboração de uma rede neural artificial, capaz de classificar diferentes padrões mastigatórios de caprinos.

4. MATERIAIS E MÉTODOS

4.1 AQUISIÇÃO DOS SINAIS REFERENTES À MASTIGAÇÃO, ANÁLISE E CLASSIFICAÇÃO

Esta proposta baseia-se na classificação de sinais de mastigação medidos através do uso de sensores à fibra ótica (FBG). Detalhes sobre os procedimentos relacionados podem ser encontrados em Wosniak *et al.* (2012).

Para se obter os dados referentes a diferentes casos de mastigações, utilizou-se um crânio de caprino cedido pelo Instituto Agrônomo do Paraná (IAPAR). O mesmo passou por um processo de dessecação e limpeza de resíduos. Para refazer a ligação do maxilar com o crânio do caprino foi utilizada uma cola de silicone, a qual apresenta alta elasticidade e flexibilidade, sendo possível assim, reproduzir, aproximadamente, os movimentos mastigatórios do caprino. No seu maxilar foi colocado o sensor ótico. O crânio utilizado nos ensaios pode ser visto na Figura 10.

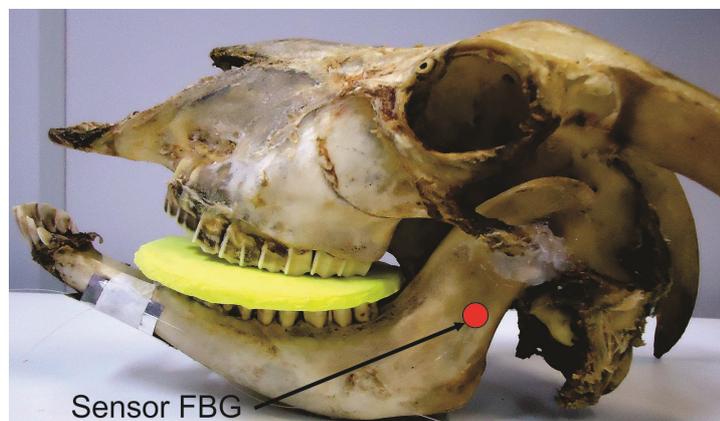


Figura 10: Cabeça cadavérica de caprino utilizada nas simulações de mastigação.
Fonte: WOSNIAK *et al.* (2012).

Inicialmente, foram realizados ensaios utilizando duas plasticinas de texturas diferentes. A primeira possui uma textura maleável e elástica, composta basicamente por pasta de goma e água, aqui denominada Plasticina A. A segunda tem uma textura esponjosa resistente, composta por espuma polimérica, denominada Plasticina B. Os movimentos mastigatórios foram realizados manualmente, com cuidado necessário para ser mantida a mesma posição, frequência, ângulo e intensidade nos movimentos de repetição.

Para a coleta destes dados (sinais) utilizou-se o interrogador D1410 e o programa *CatmanEasy*, da empresa HMB[®]. A taxa de amostragem utilizada nos ensaios foi de 1 kHz. O sensor FBG com comprimento de onda de 1545 nm.

Os sinais encontrados durante as aquisições da mastigação com plasticinas apresentaram um padrão bem definido, o que estimulou expandir a simulação para pastagens utilizadas diariamente pelos animais. Assim, também foram realizadas simulações de mastigações de feno de Tifton, aveia e de movimentos mastigatórios sem massa alguma na boca do crânio cadavérico. As Figuras 11 (a), 12 (a), 13 (a), 14 (a) e 15 (a) ilustram o sinal total adquirido durante as simulações das cinco mastigações. Já as Figuras 11 (b), 12 (b), 13 (b), 14 (b) e 15 (b) apresentam estes mesmos sinais, porém, durante um intervalo de 5 segundos. Podem-se observar diferenças nos sinais dos padrões mastigatórios, principalmente nos gráficos da mastigação durante o intervalo de cinco segundos.

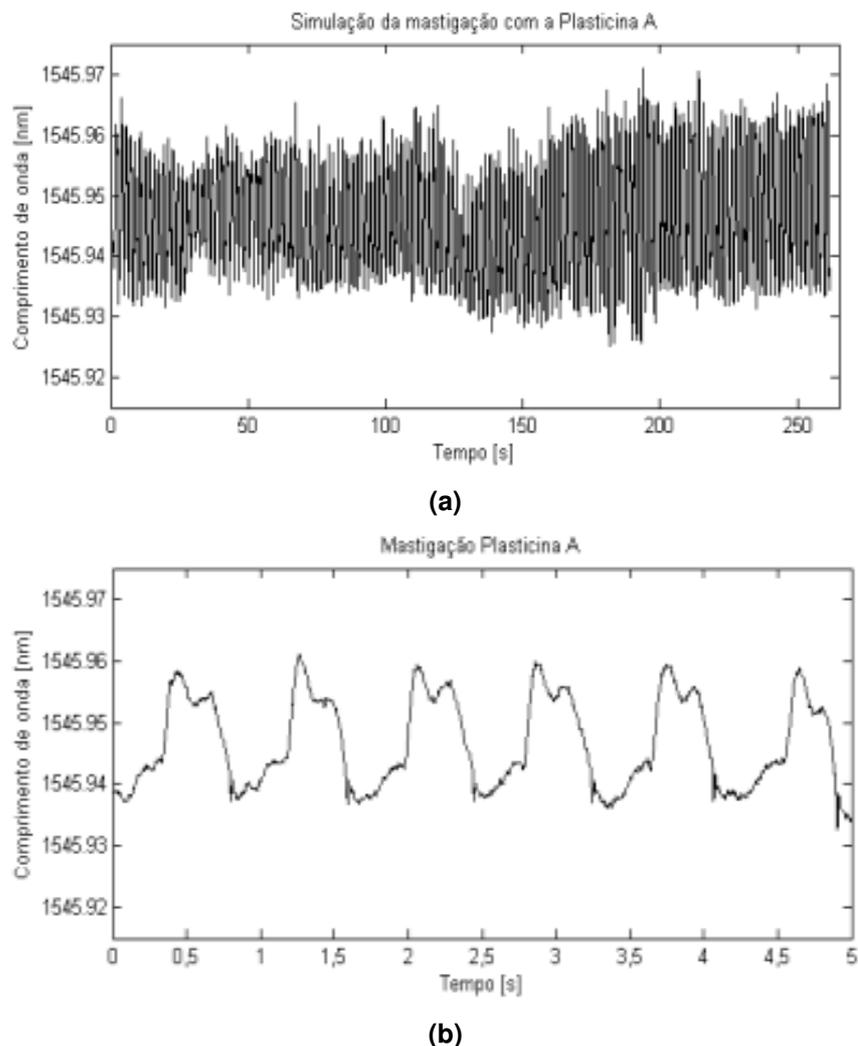
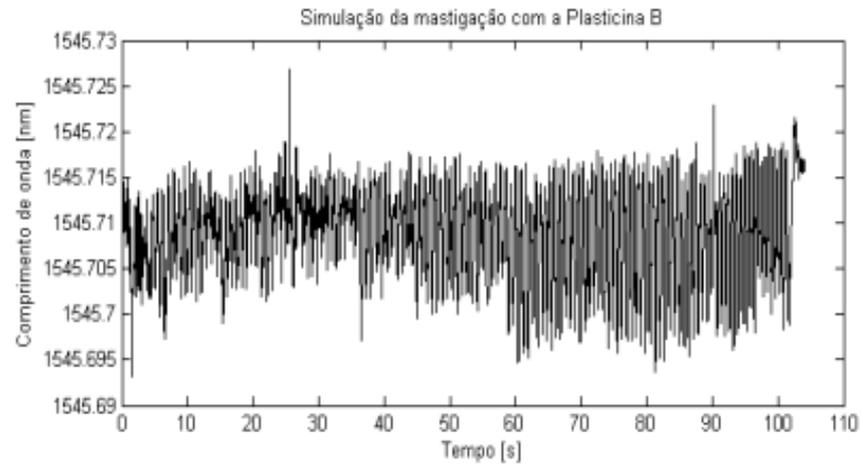
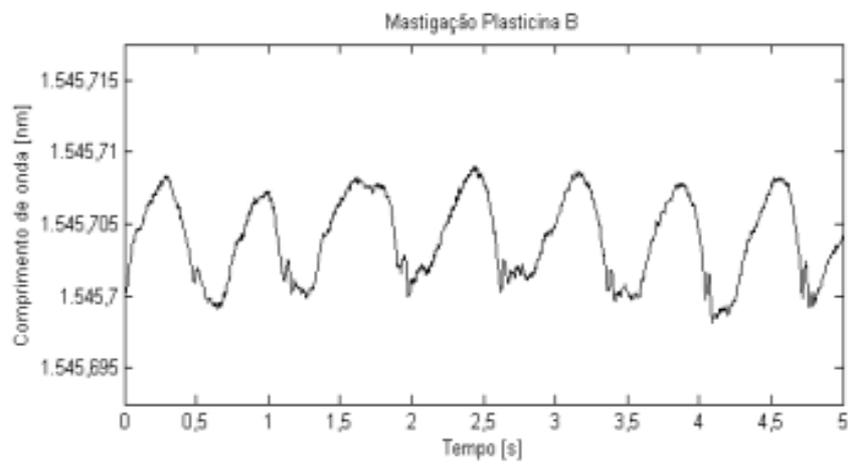


Figura 11: Sinal da mastigação: (a) durante período de simulação com a Plasticina A (260s); (b) durante intervalo de cinco segundos.

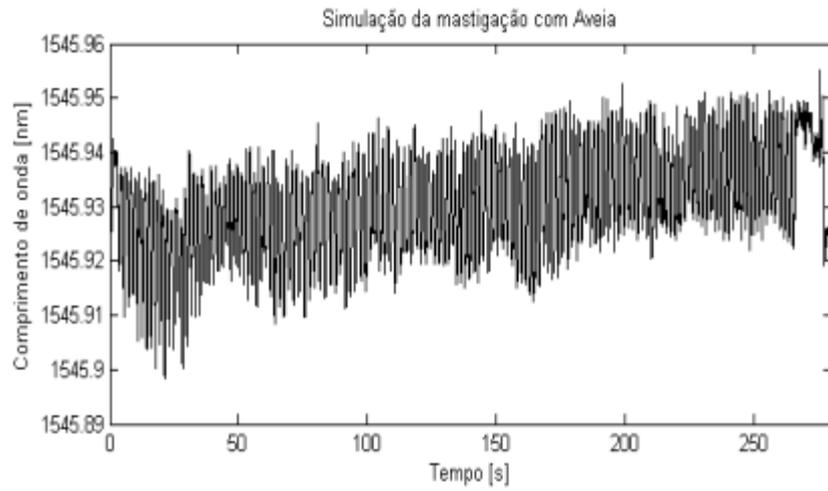


(a)

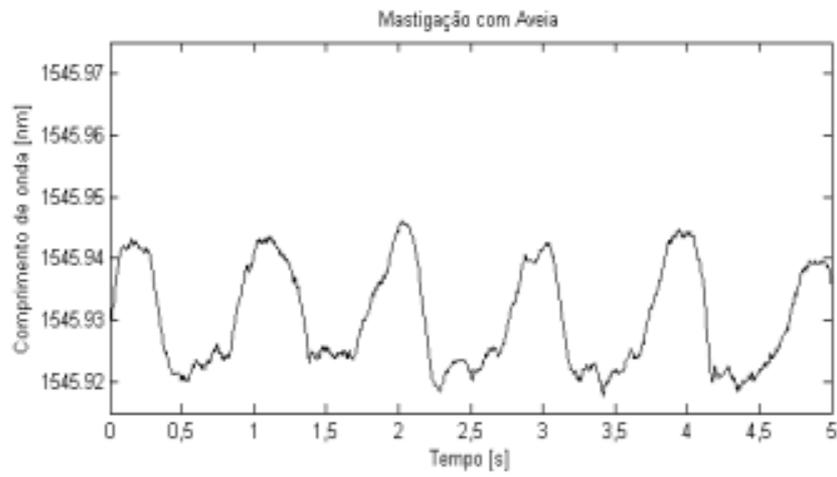


(b)

Figura 12: Sinal da mastigação: (a) durante período de simulação com a Plasticina B (110s); (b) durante intervalo de cinco segundos.

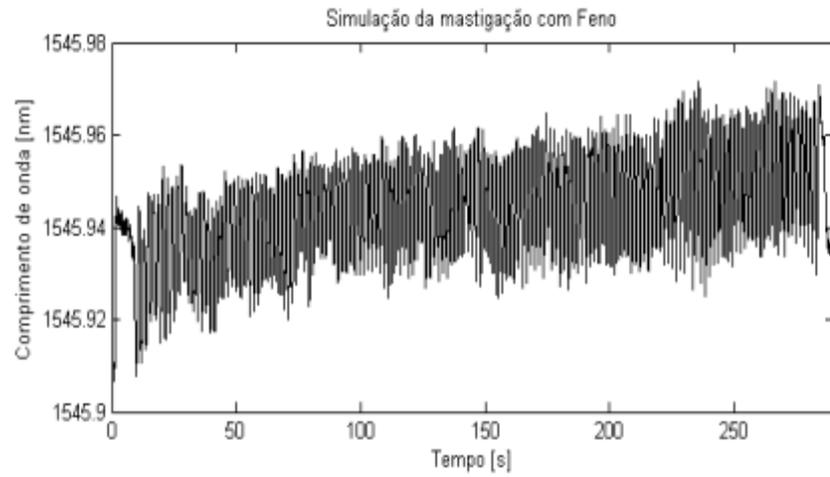


(a)

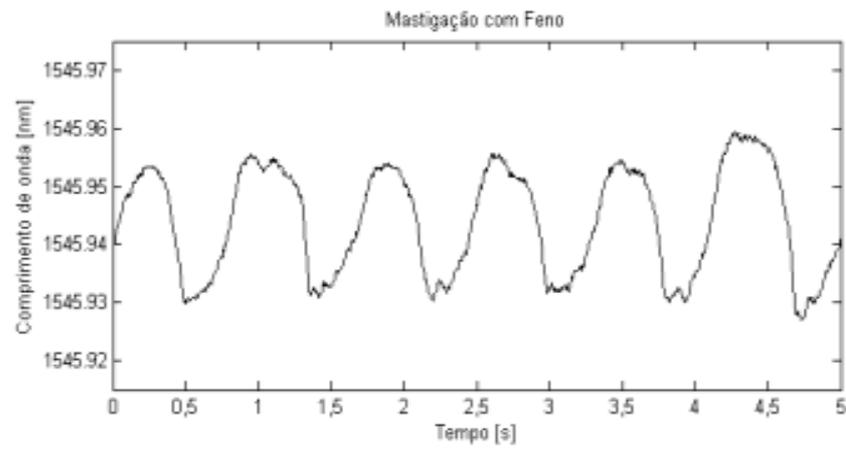


(b)

Figura 13: Sinal da mastigação: (a) durante período de simulação com Aveia (260s); (b) durante intervalo de cinco segundos.



(a)



(b)

Figura 14: Sinal da mastigação: (a) durante período de simulação com Feno de Tifton (260s); (b) durante intervalo de cinco segundos.

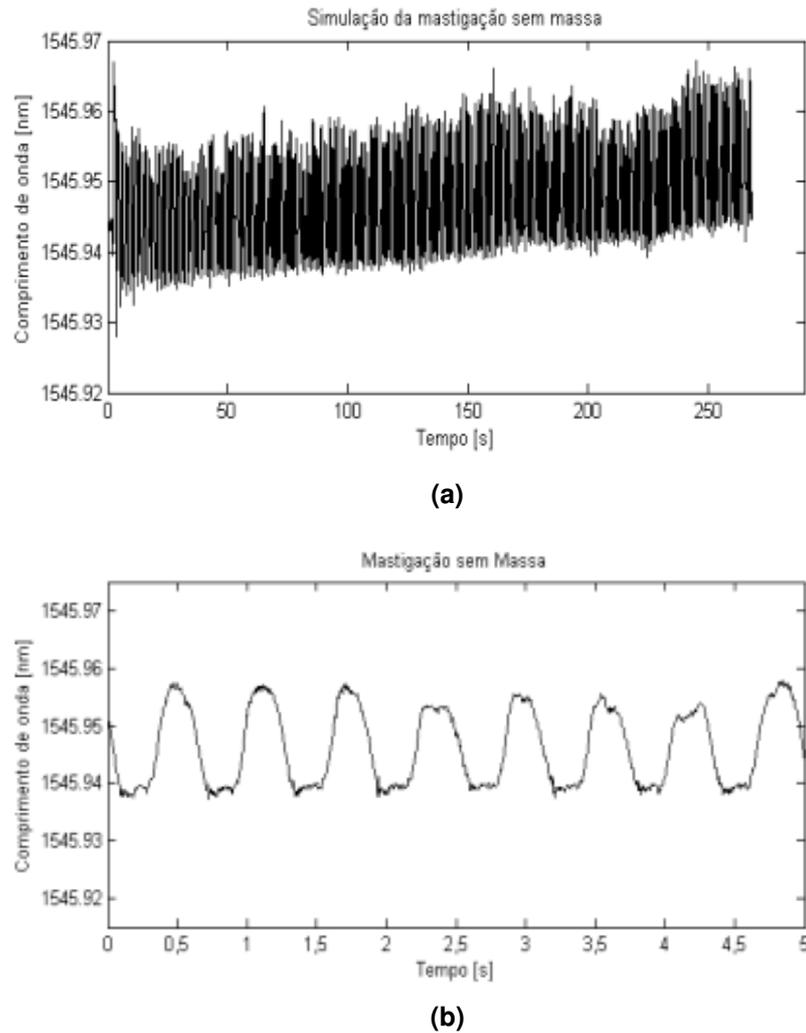


Figura 15: Sinal da mastigação sem massa: (a) durante período de simulação (260s); (b) durante intervalo de cinco segundos.

Com base nos sinais adquiridos, deseja-se desenvolver um sistema classificatório utilizando uma rede neural artificial que informe qual o tipo de material entre estes cinco que está sendo mastigado. Para a criação da rede neural será necessário tratar estes sinais de forma a criar parâmetros de entrada para treiná-la, avaliá-la e testá-la.

4.2 USO DE REDE NEURAL ARTIFICIAL PARA A CLASSIFICAÇÃO DOS PADRÕES MASTIGATÓRIOS

Para a elaboração da rede neural artificial, foi utilizado o algoritmo *backpropagation*, visto que se utilizaram parâmetros de entrada previamente

coletados durante as simulações. O *software* Matlab dispõe de uma ferramenta para aplicações de redes neurais artificiais. A utilização desta ferramenta pode se dar através de uma interface gráfica, o que facilita a utilização e a aplicação das redes neurais.

Inicialmente, foi criada uma rede neural para a classificação de apenas duas plasticinas, as quais foram denominadas Plasticina A e Plasticina B. Após análises dos resultados das classificações dos padrões mastigatórios das plasticinas, foi elaborada uma nova rede neural para a classificação de cinco padrões mastigatórios. Neste caso, os padrões considerados foram as plasticinas, aveia recém colhida, feno de Tifton e mastigação sem massa. Por fim, verificou-se a eficiência da metodologia de aprendizado e classificação de padrões das redes neurais.

4.2.1 Ferramenta para Reconhecimento de Padrões

Antes de iniciar o processo de elaboração da Rede Neural Artificial, primeiramente deve-se coletar e preparar os dados da amostra. É importante que os dados cubram a gama de entradas para a qual a RNA será usada, ou seja, todos os tipos de padrões mastigatórios. Redes multicamadas podem ser treinadas para generalizar bem dentro da faixa de entradas para qual foram treinados. No entanto, elas não têm a capacidade de extrapolar a precisão além desta faixa, por isso é importante que os dados de treinamento abranjam as diferentes variações de entrada, para que, dependendo do valor de entrada, a rede tenha dados suficientes para reconhecer e classificar a entrada proposta.

Após as coletas de dados que serão utilizados como parâmetros de entrada, há duas etapas que precisam ser realizadas antes de treinar a rede com estes dados: os dados precisam ser pré-processados e precisam ser divididos em subgrupos.

É mais fácil analisar a rede neural como tendo um bloco de pré-processamento que aparece entre a entrada e a primeira camada de rede, onde os parâmetros de entrada passam pelo processo de aprendizagem pela rede neural, a qual faz a classificação do valor de entrada a partir dos dados treinados, logo após,

um bloco de pós-processamento que aparece entre a última camada da rede emite o valor classificado na saída da rede neural, como é mostrado na Figura 16.

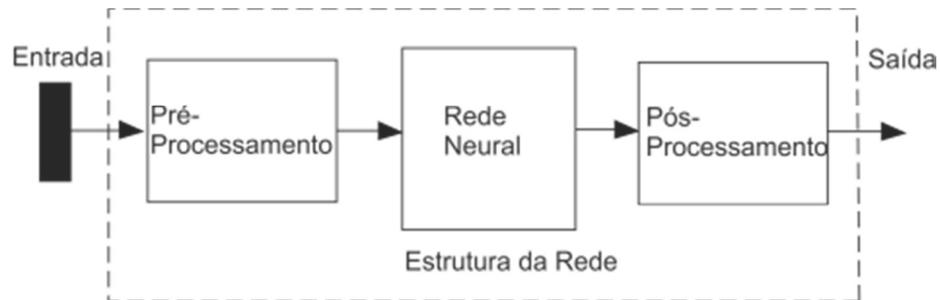


Figura 16: Blocos da RNA.
Fonte: Autoria Própria.

Segundo Demuth, Beale e Hagan (2011), a maioria das funções das ferramentas de criação de RNAs atribuem as funções de processamento de entradas e saídas da rede. Estas funções transformam os vetores de entrada e os vetores alvo em valores mais adequados para o treinamento da rede.

Para a formação da rede neural, a ferramenta *Neural Pattern Recognition Tool* (nprtool) do Matlab[®] fornece a arquitetura *feedforward* multicamadas. Para utilizar o *toolbox*, inicialmente precisa-se criar a matriz de entrada (*inputs*) e a matriz de saída, denominadas matriz-alvo (*targets*). A partir desses dados, pode-se elaborar e treinar uma rede, avaliar seu desempenho usando o erro médio quadrático e matrizes confusão.

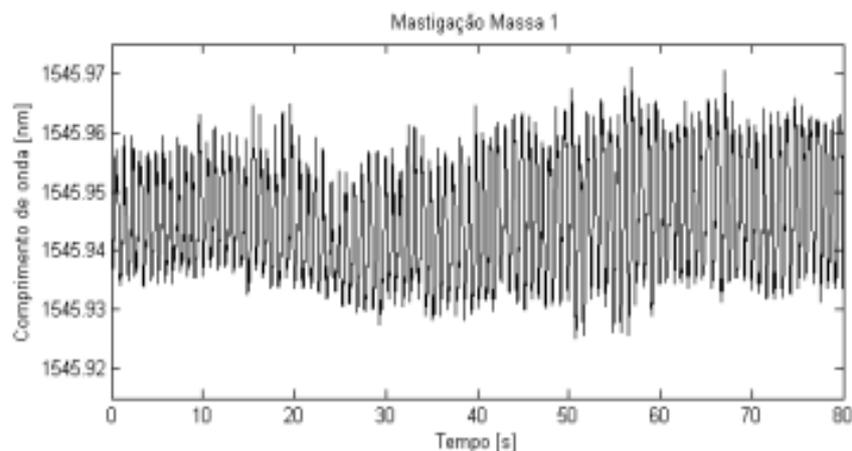
4.2.2 RNA para classificação de dois padrões mastigatórios

A criação das Redes Neurais foi dividida em duas etapas. Inicialmente foi designado um algoritmo para a criação de uma Rede Neural apenas para a classificação dos padrões mastigatórios das duas plasticinas e os resultados foram analisados. Depois deste processo, criou-se uma Rede Neural contemplando não só a classificação dos padrões mastigatórios das plasticinas, como também das mastigações de feno de Tifton, aveia recém colhida e sem massa na boca do crânio.

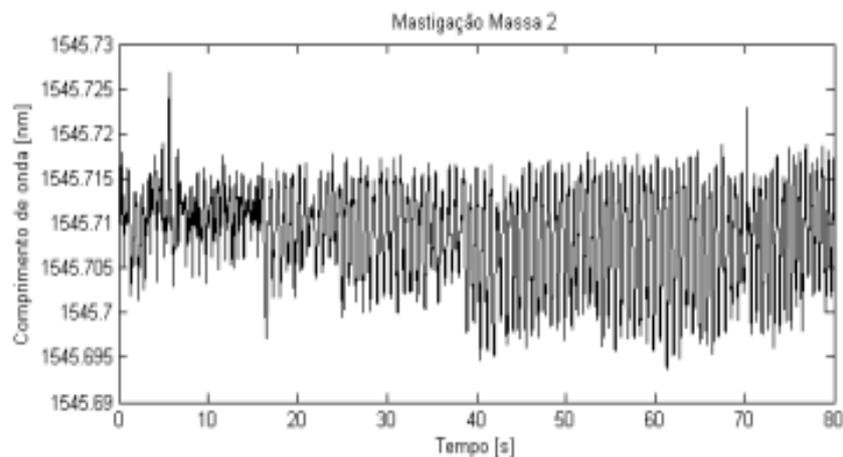
Como mencionado anteriormente, o primeiro passo foi tratar os sinais, deixando todos com 80 segundos de simulação de mastigações. Os códigos

implementados para selecionar o trecho da simulação utilizados na elaboração da RNA estão ilustrados nas Listagens 1 e 2 no Apêndice A.

Os sinais foram divididos (através de um código criado no Matlab) em 80 formas de onda de 1000 pontos para cada tipo de mastigação. Cada vetor representando 1 segundo da mastigação, conforme os gráficos abaixo. Estas formas de onda foram utilizadas para a criação, treinamento e teste da RNA. A Figura 17 mostra o sinal gerado pela simulação durante 80 segundos. A Figura 18 ilustra a simulação das mastigações de ambas as plasticinas, em um intervalo de cinco segundos pode-se notar uma nítida diferença nas formas de ondas das referidas mastigações. Na formação da matriz de entrada dividiu-se os sinais referentes às mastigações de ambas as plasticinas em 80 outras matrizes de 1000 elementos cada. Isso corresponde a uma matriz de 1000 elementos para cada segundo. A Figura 19 ilustra o sinal da simulação referente à 1 segundo de mastigação.

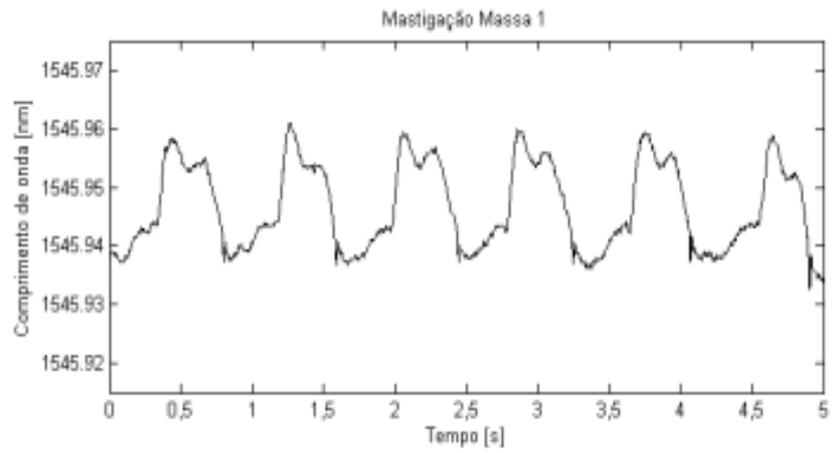


(a)

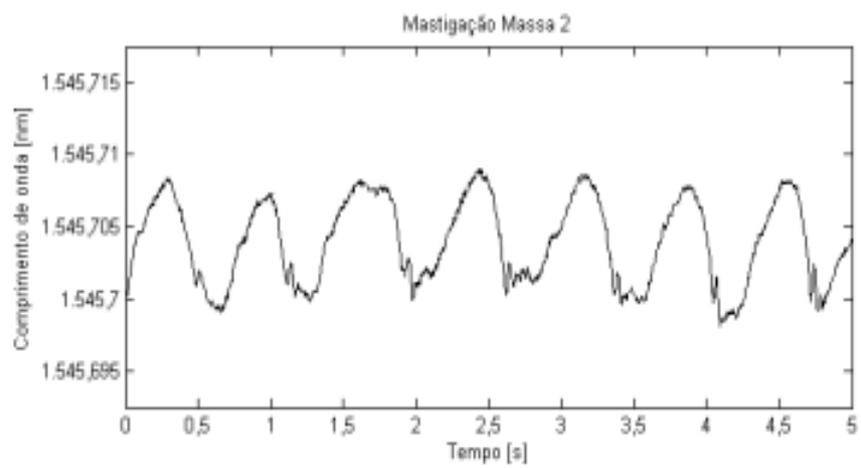


(b)

Figura 17: Sinal da mastigação adquirida durante 80 segundos com: (a) Plasticina A; (b) Plasticina B.



(a)



(b)

Figura 18: Mastigação em um intervalo de 5 segundos com: (a) Plasticina A; (b) Plasticina B.

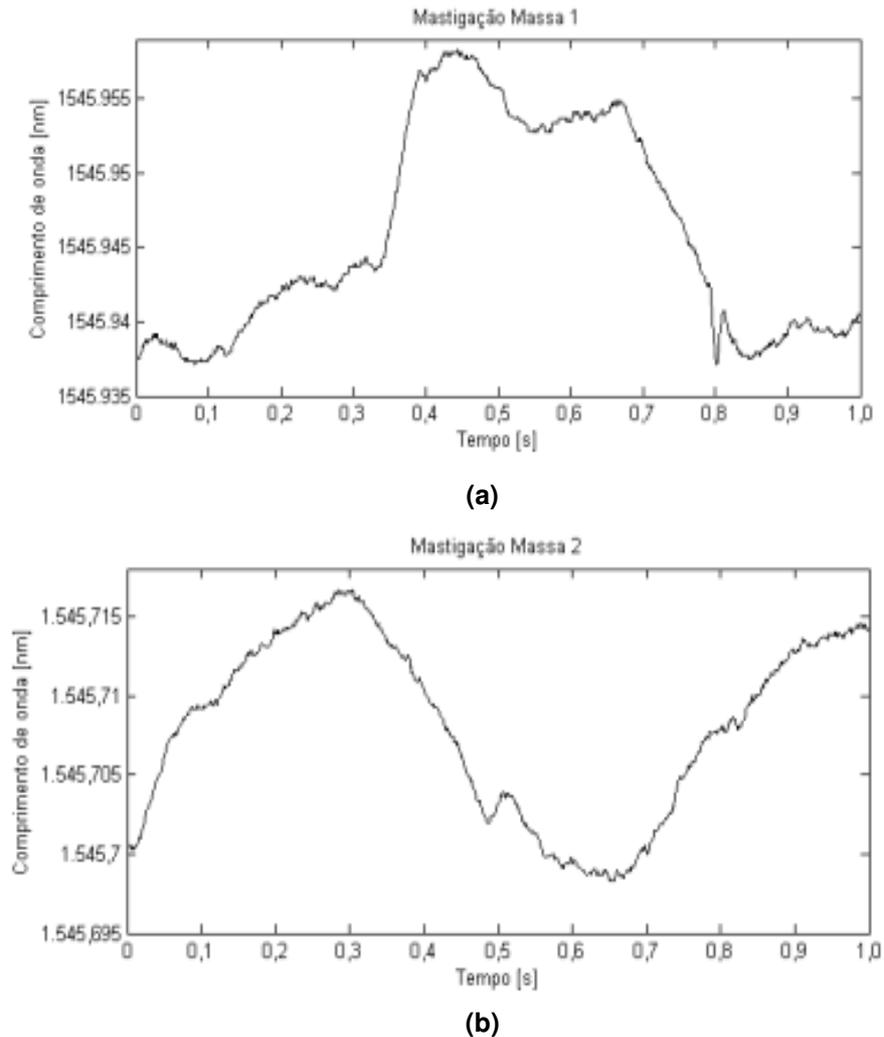


Figura 19: Mastigação em um intervalo de 1 segundo com: (a) Plasticina A; (b) Plasticina B.

A Rede Neural Artificial foi criada utilizando a ferramenta de reconhecimento de padrões *Neural Network Pattern Recognition* do software Matlab[®]. Utilizando esta ferramenta para buscar uma solução do problema de reconhecimento de padrões, inicialmente é necessário organizar um conjunto de vetores de entrada, como colunas em uma matriz. Em seguida, organizar outro conjunto de vetores "alvo", para que eles indiquem as classes a que os vetores de entrada serão atribuídos.

A Listagem 3, ilustrada no Apêndice A, mostra o código criado para a elaboração do primeiro vetor do conjunto de vetores de entrada da mastigação da plasticina A. A Listagem 4 mostra o código criado para a elaboração do primeiro vetor do conjunto de vetores de entrada da mastigação da plasticina B.

Para a criação do conjunto de vetores alvo foi definido um valor alvo escalar 1 ou 0, indicando para qual classe de entrada correspondente o valor

pertence. Os vetores alvo podem ter N elementos, onde para cada vetor alvo, um elemento será 1 e os outros receberão 0. Portanto, para os 80 primeiros vetores de entrada referente à mastigação da plasticina A (cdo1 ao cdo80) foi atribuído o valor 0 como vetor alvo, e para os 80 vetores de entrada da plasticina B (cdo81 ao cdo160) atribuiu-se o valor 1, conforme é ilustrado nas Listagens 5 e 6 do Apêndice A.

Com os vetores de entrada (*Inputs*) denominados "P" e os vetores alvo (*Targets*) denominado "T" criados, pode-se começar a utilizar a ferramenta *Neural Network Pattern Recognition*. Inicialmente é feita a seleção dos vetores, tanto o de entrada quanto o alvo. A Figura 20 ilustra a interface da ferramenta do Matlab.

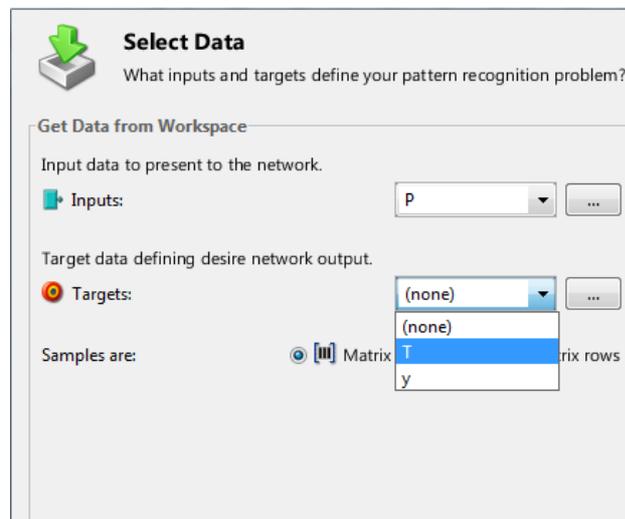


Figura 20: Seleção dos vetores de entrada e alvos.
Fonte: Autoria Própria.

O próximo passo é definir a porcentagem das amostras que serão retiradas do treinamento da Rede Neural com o intuito de serem usadas na validação e teste da mesma. Para a RNA em questão, foram separados 15% das amostras para validação e 15% para o teste, conforme é mostrado na Figura 21. Com estas configurações, os vetores de entrada e vetores alvos serão divididos aleatoriamente em três grupos como segue:

- 70% usados para o treinamento;
- 15% são usados para validar o que a rede estará generalizando e parar o treinamento antes de reajustar;
- Os 15% últimos são usados como um teste completamente independente da generalização da rede.

A Figura 21 ilustra o procedimento de parametrização das amostras referentes à validação, treinamento e teste das amostras.

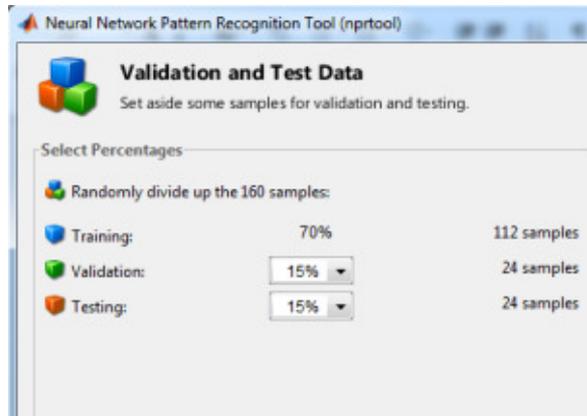


Figura 21: Definição da porcentagem destinada à validação e teste.
Fonte: Autoria Própria.

Depois desta etapa, é definido o número de neurônios utilizados na camada oculta. Para este caso utilizou-se 10 neurônios, como é ilustrado na Figura 22.

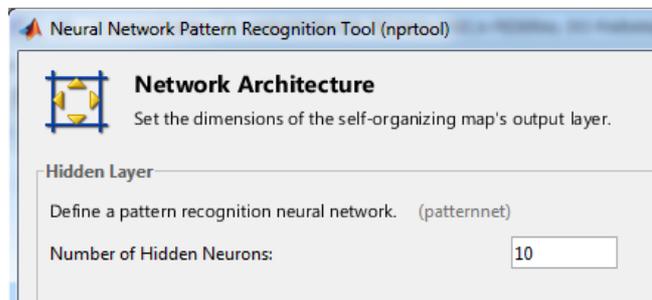


Figura 22: Definição da quantidade de neurônios utilizados na camada oculta.
Fonte: Autoria Própria.

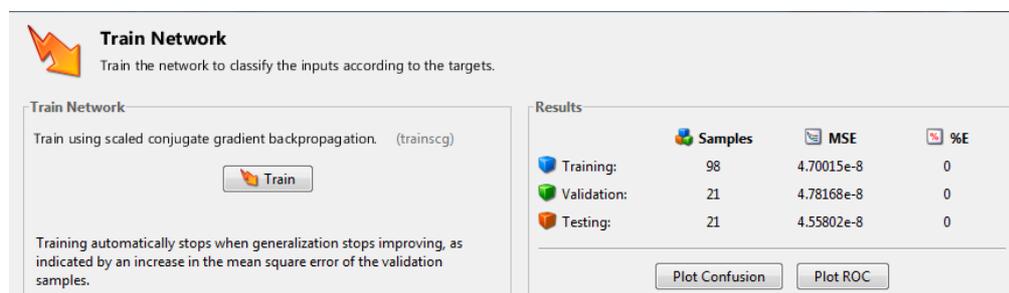


Figura 23: Realização do treinamento; geração da matriz confusão e curvas ROC.
Fonte: Autoria Própria.

Logo após é realizado o treinamento com base em 112 amostras, conforme Figura 23. Com a rede neural treinada, é possível gerar a Matriz Confusão para se obter o desempenho classificatório da rede neural.

4.2.3 RNA para classificação de cinco padrões mastigatórios

Para a classificação de cinco padrões, também tratou-se os sinais referente as simulações de mastigação com feno de Tifton, aveia recém colhida e da mastigação sem massa, deixando tais sinais com comprimento referente à 80 segundos de simulação. Este procedimento é necessário para padronizar os sinais que serão utilizados na elaboração da rede neural artificial, além de escolher um trecho melhor definido, retirando os pontos iniciais e finais, onde se tem uma maior interferência ocasionada pela simulação manual.

Os códigos da Listagem 8, ilustrados no Apêndice B, mostram a forma utilizada para separar o trecho da simulação utilizado na RNA. Os mesmos procedimentos relatados no item 4.2.2 para a criação da RNA de classificação dos padrões mastigatórios das plasticinas foram repetidos para a criação da RNA com os cinco padrões mastigatórios.

Os vetores de 1 segundo formam um conjunto de 80 vetores de 1000 pontos cada (Figuras 24, 25, 26, 27 e 28).

Para este código de classificação dos cinco padrões mastigatórios, foram criados 400 vetores, onde os sinais foram divididos em 80 formas de onda de 1000 pontos para cada mastigação. Cada forma de onda de 1000 pontos é um vetor que representa 1 segundo da mastigação. As Figuras 29, 30, 31, 32 e 33 ilustram 5 formas de onda de 1000 pontos cada, representando 5 segundos de simulação de mastigação.

Os cinco conjuntos de 80 vetores (aveia recém colhida, feno de Tifton, sem massa, plasticinas A e B) formam a matriz de entrada (*inputs*) que é utilizada para a criação, treinamento e teste da rede neural artificial.

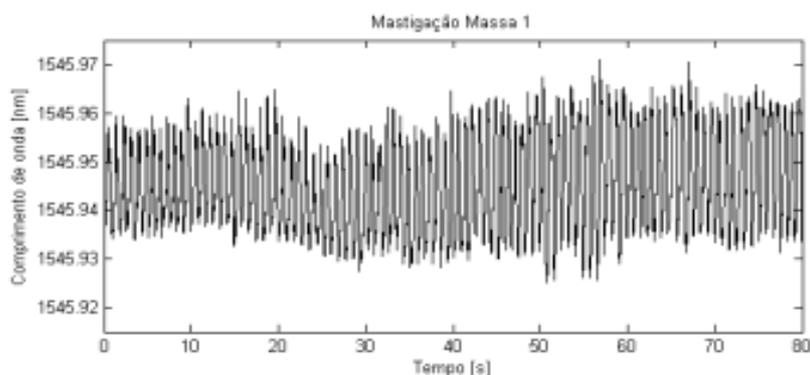


Figura 24: Sinal da mastigação adquirida durante 80 segundos com Plasticina A.

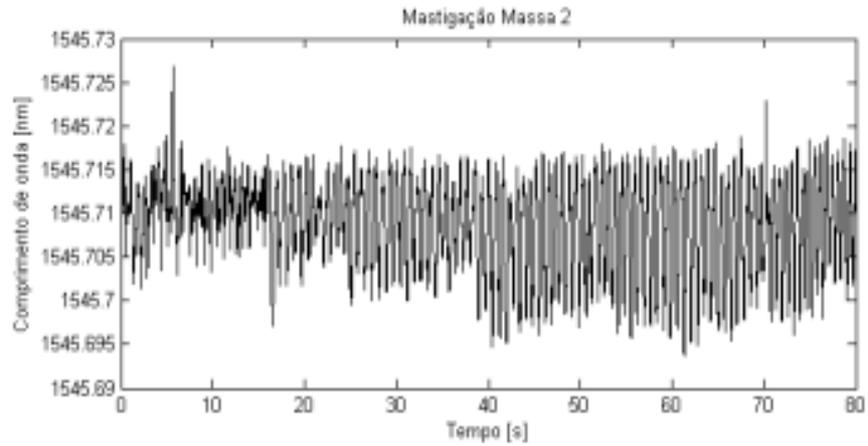


Figura 25: Sinal da mastigação adquirida durante 80 segundos com Plasticina B.

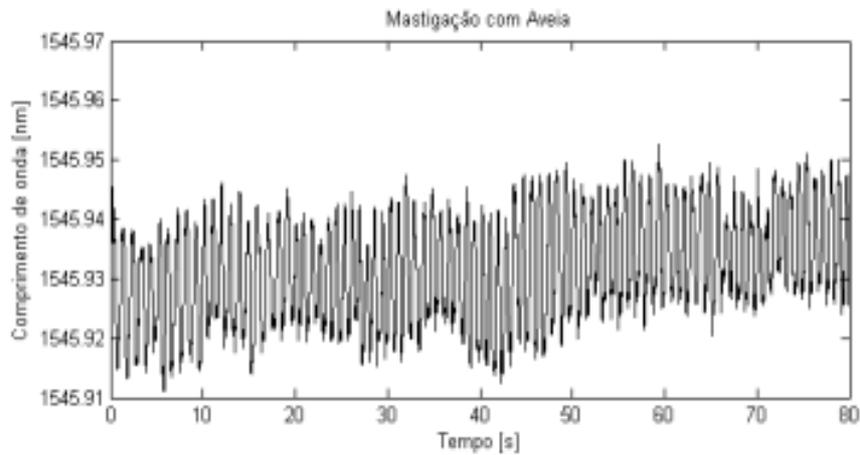


Figura 26: Sinal da mastigação adquirida durante 80 segundos com Aveia recém colhida.

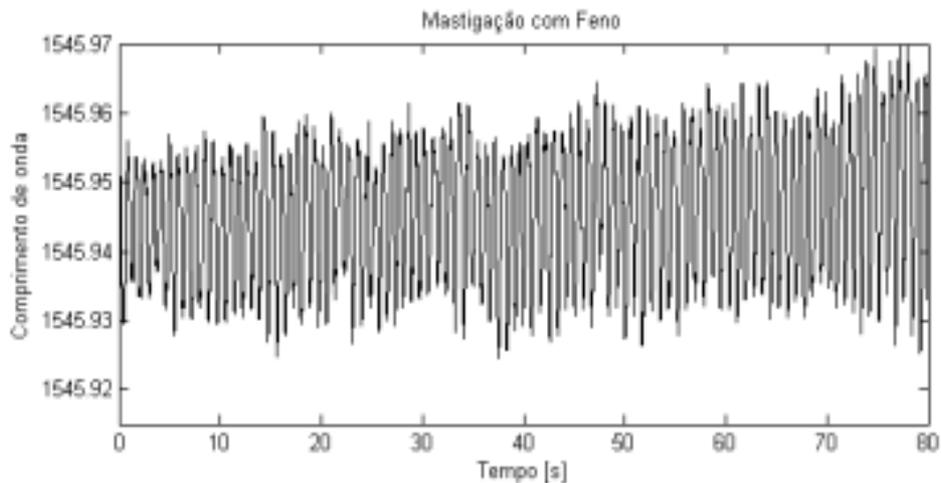


Figura 27: Sinal da mastigação adquirida durante 80 segundos com Feno de Tifton.

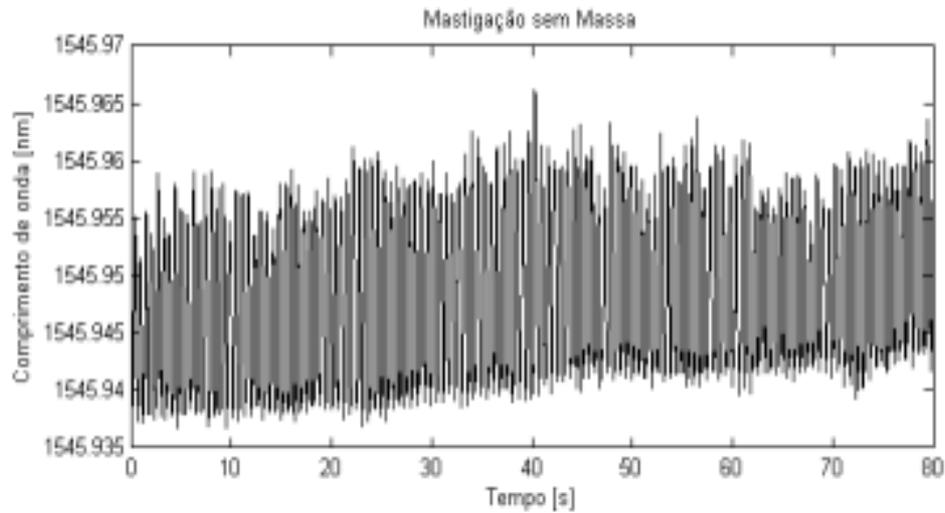


Figura 28: Sinal da mastigação adquirida durante 80 segundos sem Massa.

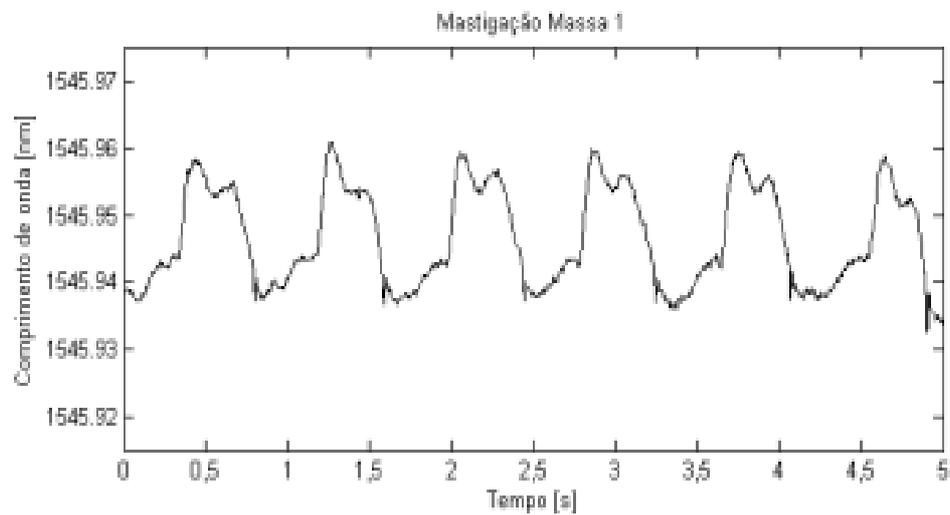


Figura 29: Mastigação em um intervalo de 5 segundos com Plasticina A.

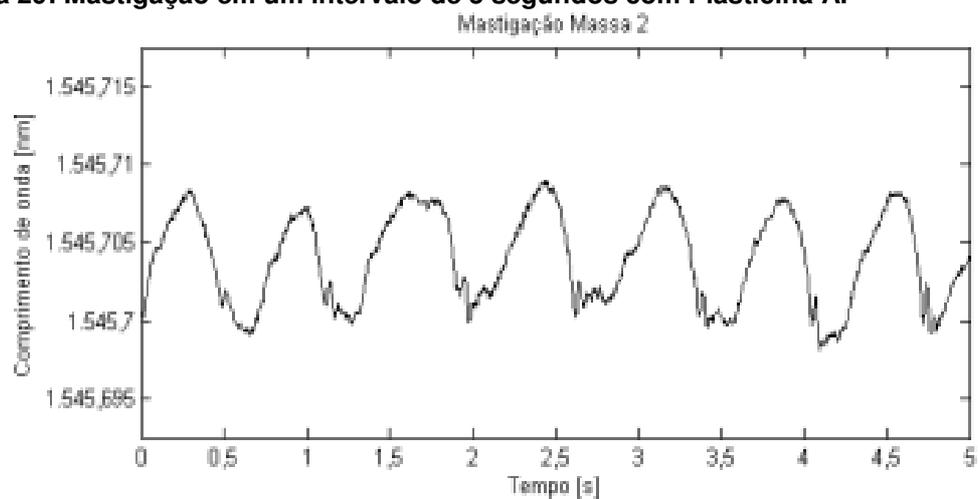


Figura 30: Mastigação em um intervalo de 5 segundos com Plasticina B.

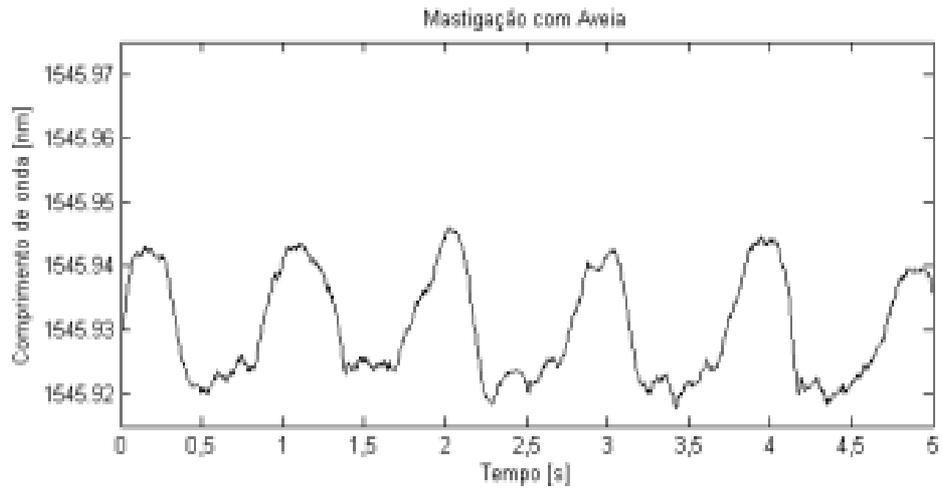


Figura 31: Mastigação em um intervalo de 5 segundos com Aveia.

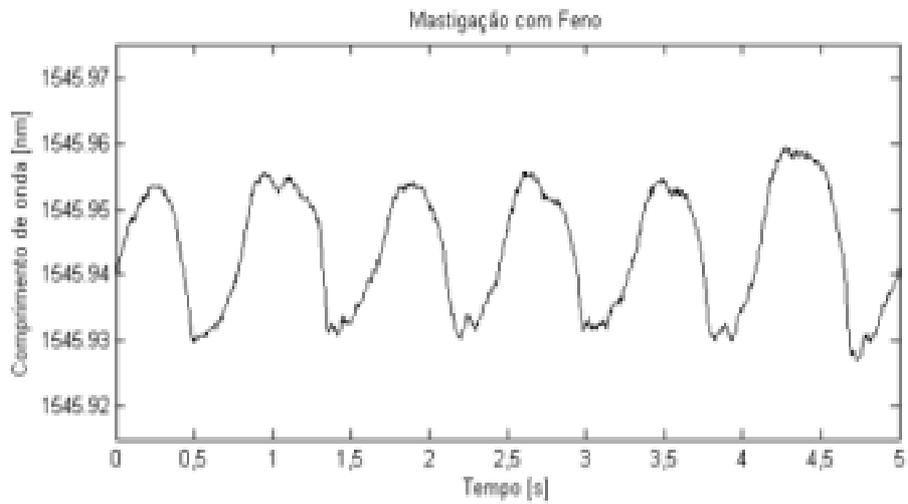


Figura 32: Mastigação em um intervalo de 5 segundos com Feno de Tifton.

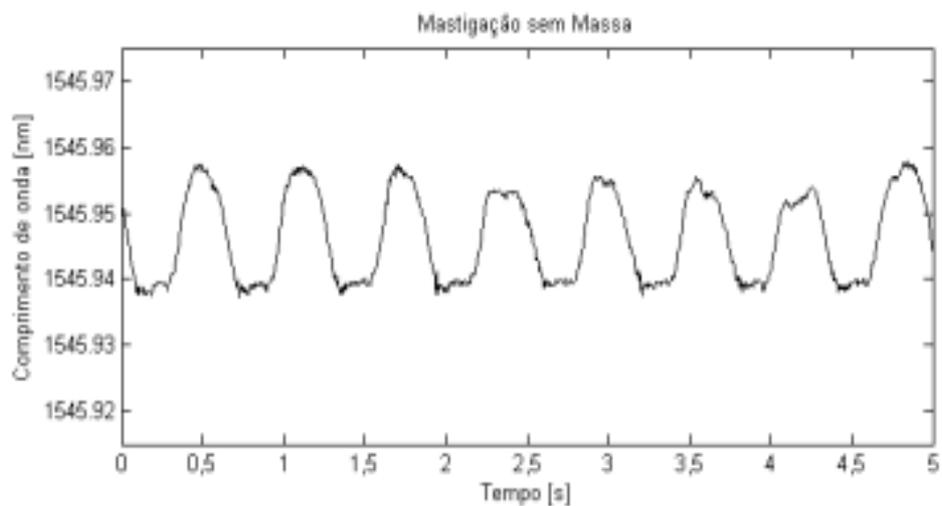


Figura 33: Mastigação em um intervalo de 5 segundos sem Massa.

A Listagem 9, ilustrada no Apêndice B, mostra os códigos criados para a elaboração do primeiro vetor dos conjuntos de vetores de entrada das mastigações mencionadas.

O conjunto de vetores alvo para as cinco mastigações teve a seguinte relação:

- 0 0 0 0 1 para os vetores referentes a mastigação de aveia recém colhida;
- 0 0 0 1 0 para os vetores referentes a mastigação de feno de Tifton;
- 0 0 1 0 0 para os vetores referentes a mastigação sem massa;
- 0 1 0 0 0 para os vetores referentes a mastigação da plasticina A;
- 1 0 0 0 0 para os vetores referentes a mastigação da plasticina B;

indicando para qual classe de entrada correspondente o valor pertence. A Listagem 10 do Apêndice B ilustra parte do código onde foram definidos os valores alvo para cada valor de entrada.

Com a matriz de entrada (inputs) denominados "P" e a matriz alvo (targets) denominado "T" criados, pode-se então utilizar novamente a ferramenta *Neural Network Pattern Recognition*, para o reconhecimento dos cinco padrões mastigatórios. Realizando os mesmos procedimentos mencionados e ilustrados anteriormente, alterando apenas a quantidade de neurônios na camada oculta para 35, pode-se gerar as matrizes confusão para se obter o resultado da rede neural artificial para a classificação dos cinco padrões mastigatórios. Os resultados estão apresentados no capítulo cinco.

5 APRESENTAÇÃO E ANÁLISE DE RESULTADOS

O presente capítulo tem o propósito de apresentar e analisar os resultados obtidos no desenvolvimento deste trabalho. Serão apresentados os sinais adquiridos durante as simulações de mastigação bem como os resultados de classificação fornecidos pelas redes neurais criadas e treinadas.

5.1 RESULTADOS REFERENTES À RNA PARA CLASSIFICAÇÃO DE DOIS PADRÕES MASTIGATÓRIOS

Para Demuth, Beale e Hagan (2011), o desempenho da rede é medido em termos de erro médio quadrático e medido para cada um dos conjuntos de Validação, Treinamento e Teste. Uma maneira de saber quão bem os dados da rede neural foram ajustados é através da matriz confusão. Com a matriz confusão é possível analisar a resposta da rede. Tal matriz mostra vários tipos de erros que ocorrem até o final do treinamento da rede. Na Figura 34 está a matriz confusão deste caso, na qual as células diagonais em cada tabela mostram o número de casos corretamente classificados e as células fora da diagonal mostram os casos erroneamente classificados. A célula azul no canto inferior direito mostra o percentual total de casos corretamente classificados (em verde) e a porcentagem total de casos erroneamente classificados (em vermelho).

De acordo com Stehman (1997), a matriz confusão é uma tabela que especifica e que permite a visualização do desempenho de um algoritmo, normalmente um aprendizado supervisionado. Cada coluna da matriz representa as instâncias de uma classe prevista (*targets*), enquanto cada linha representa cada instância de uma classe real (*inputs*).

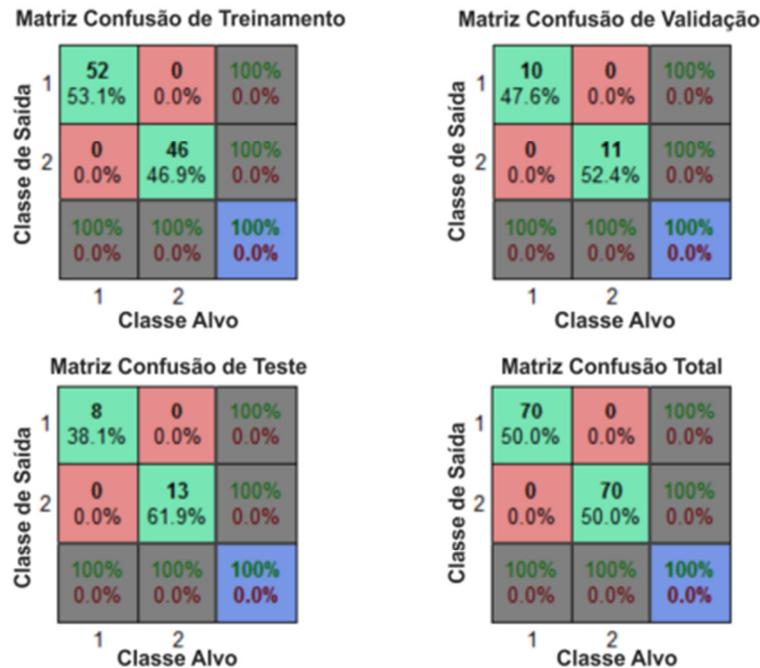


Figura 34: Matriz confusão, resposta da validação, teste e treinamento da RNA.
Fonte: Autoria Própria.

O reconhecimento para os três conjuntos de dados (validação, treinamento e teste) mostram resultados satisfatórios. Observa-se que as porcentagens de casos erroneamente classificados (quadros vermelhos) apresentam um erro de 0% (erro nulo), indicando que a RNA obteve um ótimo aprendizado para o caso de classificação de dois padrões.

A partir dos resultados da matriz confusão, pode-se ver que os testes de dados das redes neurais para identificação dos sinais apresentaram 100% de acerto para os testes realizados, tornando possível a identificação dos dois tipos de sinais (plasticinas A e B). A Figura 35 mostra em diagrama de blocos, a forma construtiva da RNA utilizada para a classificação dos padrões mastigatórios das duas plasticinas.

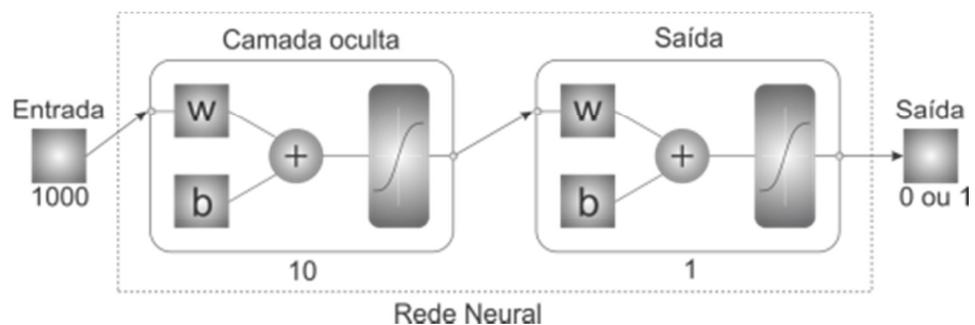


Figura 35: Demonstração da rede neural usada.
Fonte: Autoria Própria.

A partir da rede neural criada através da ferramenta *Neural Pattern Recognition Tool*, pode-se gerar um *script* onde é possível reproduzir todas as etapas realizadas utilizando a interface de parametrização da *toolbox*. A Listagem 7 ilustrada no Apêndice A, mostra o código o qual apresenta os passos para a realização da rede neural artificial manualmente, utilizando o *workspace* do Matlab.

Este *script* nomeia as variáveis do conjunto de matrizes de entrada (P) e o conjunto de matrizes alvo (T). Logo após é definida a quantidade de neurônios que será utilizada na camada oculta. Então é criada a rede neural e realizado o seu treinamento, validação e teste. Logo após, é possível exibir a matriz confusão para análise do desempenho classificatório da rede neural.

5.2 RESULTADOS REFERENTES À RNA PARA CLASSIFICAÇÃO DE CINCO PADRÕES MASTIGATÓRIOS

As Figuras 36 e 37 ilustram as matrizes confusão geradas com um mesmo código que implementa a RNA. Porém, cada matriz foi gerada a partir de um treinamento diferente, o qual é realizado através da interface mostrada na Figura 23. Para cada treinamento a ferramenta *Neural Pattern Recognition Tool* escolhe diferentes conjuntos de dados dentro da porcentagem determinada para o treinamento, conforme demonstrado pela Figura 21. Estes dados são também apresentados em uma sequência diferente para cada treinamento. Isto leva a RNA a fornecer resultados diferentes.

Neste conjunto de dois treinamentos distintos, observa-se que cada treinamento fornece um resultado diferente. A Figura 36 ilustra a matriz confusão para um treinamento onde a rede neural artificial conseguiu classificar corretamente 83,5% das amostras e que apenas 16,5% foram erroneamente classificadas. Entretanto, analisando a matriz confusão da Figura 37, pode-se observar que as amostras corretamente classificadas foram menores, ou seja, a porcentagem de acertos foi menor.

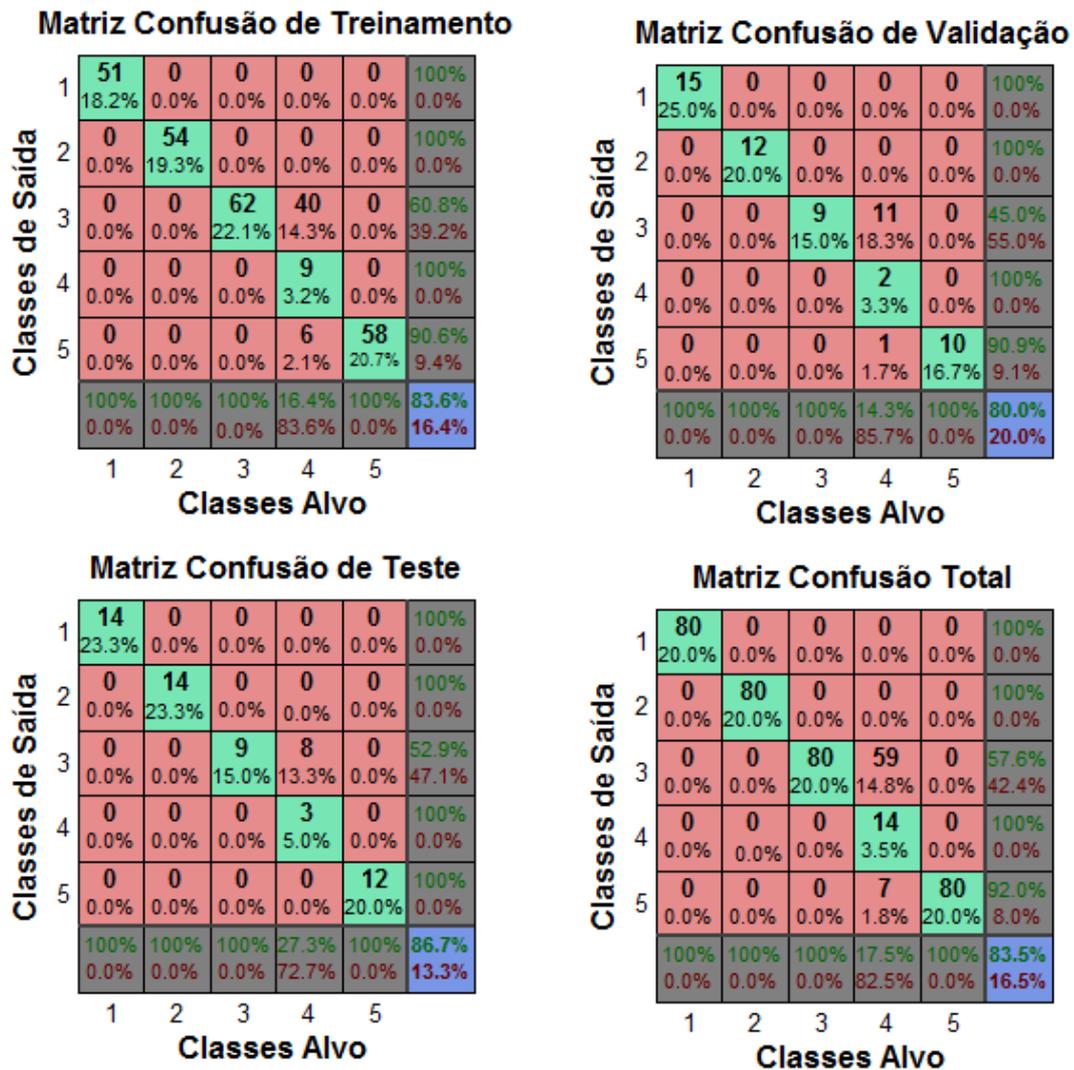


Figura 36: Matriz confusão, resposta da validação, teste e treinamento da RNA – 83,5%.
Fonte: Autoria Própria.

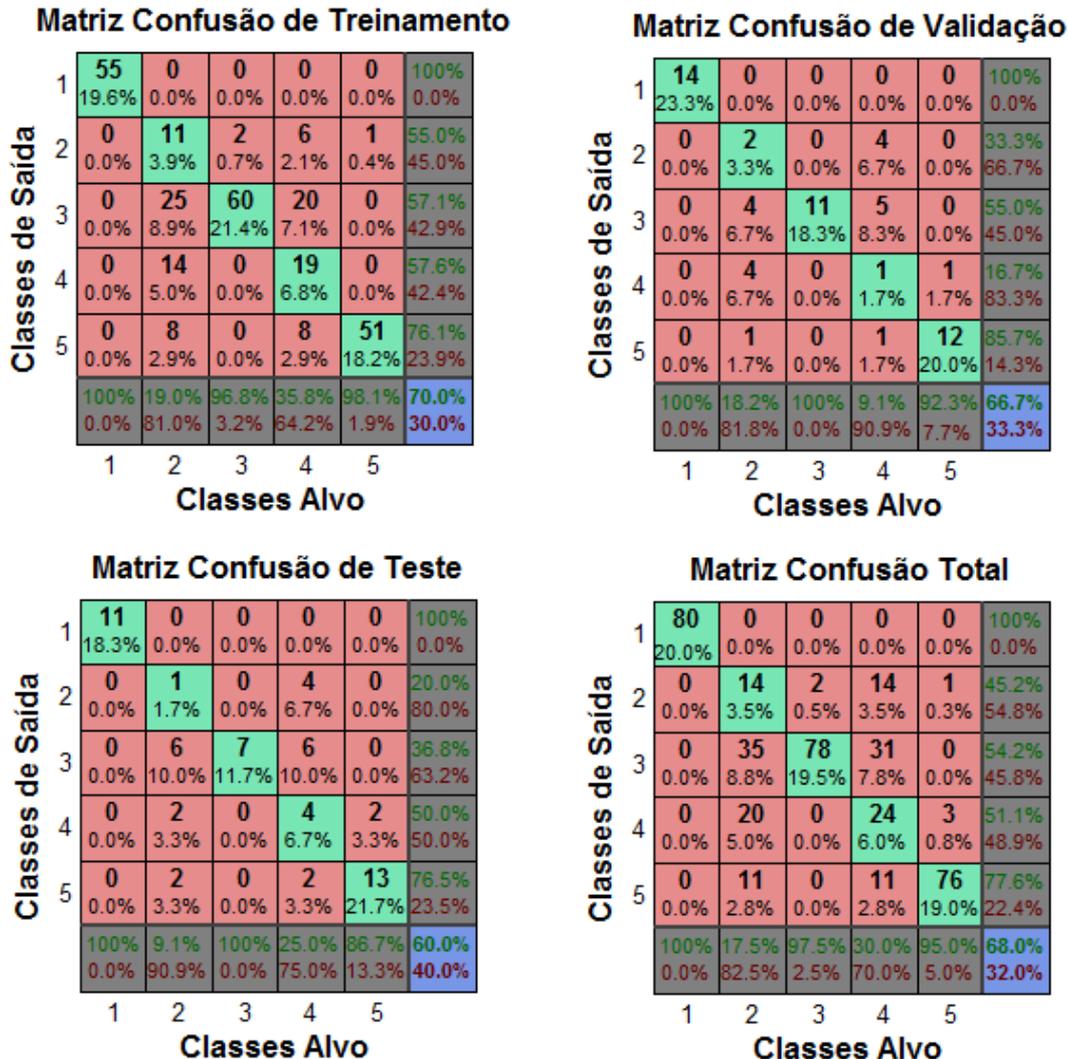


Figura 37: Matriz confusão, resposta da validação, teste e treinamento da RNA – 68,5%.
Fonte: Autoria Própria.

Pode-se notar através dos resultados das matrizes confusão, que a classificação de 5 padrões pela rede neural não foi tão satisfatória quanto à resposta da rede para um cenário contendo apenas dois padrões. A rede neural treinada para a classificação dos cinco padrões mastigatórios, apresentou certa variação na eficiência de classificação dos padrões. Dependendo do treinamento, os resultados forneceram maior ou menor taxa de acerto na classificação dos padrões.

Do mesmo modo da rede neural criada para a classificação dos padrões mastigatórios das duas plasticinas utilizando a ferramenta *Neural Pattern Recognition Tool* para a rede neural de classificação dos cinco padrões mastigatórios, obtêm-se um script usado para reproduzir todas as etapas realizadas utilizando a *toolbox*. A Listagem 11, ilustrada no Apêndice B, mostra o código onde apresenta os passos para a realização da rede neural artificial para classificação dos cinco padrões mastigatórios.

5.3 ANÁLISE DOS RESULTADOS OBTIDOS

Avaliando os resultados da rede neural artificial criada para a classificação dos padrões mastigatórios das duas plasticinas, pode-se dizer que a rede apresentou resultados de classificação satisfatórios.

Outra característica que contribuiu para o resultado satisfatório da rede neural foi o fato de se ter apenas dois padrões com sinais diferentes entre si. Adicionalmente, as massas utilizadas possuíam texturas bem distintas. Uma possuía uma textura maleável e elástica, composta basicamente por pasta de goma e água, e a outra uma textura esponjosa resistente, composta por espuma polimérica.

A partir dos resultados obtidos por meio das matrizes confusão, geradas a partir do algoritmo de classificação dos cinco padrões mastigatórios (aveia recém colhida, feno de Tifton, mastigação sem massa, plasticina A e B), pode-se dizer que os resultados apresentados não foram tão satisfatórios quanto à resposta da rede com apenas as duas plasticinas, onde tais resultados apresentaram um aprendizado com 100% de amostras corretamente classificadas. Já para os cinco padrões mastigatórios, o maior valor de amostras corretamente classificadas não passou de 83,5% do total de amostras.

Analisando os resultados das matrizes confusão, observou-se certa variação na resposta do desempenho da classificação das amostras da rede neural artificial. Isto ocorre porque, para este algoritmo, foram utilizados sinais de simulação de mastigação com feno de Tifton e aveia recém colhida.

Tais materiais contêm um formato irregular, ou seja, possuem talos, folhas e sementes que possuem características diferentes. Assim os sinais de tais mastigações não possuíram um padrão tão definido quanto o das plasticinas. Além do fato de que os movimentos mastigatórios foram realizados manualmente, mesmo se tendo o cuidado para manter a mesma posição, frequência, ângulo e intensidade nos movimentos de repetição.

6 DESENVOLVIMENTO DE UMA INTERFACE GRÁFICA PARA O USUÁRIO

Para o desenvolvimento da interface gráfica foi utilizada a ferramenta *GUIDE* do Matlab que se trata de um ambiente de criação de interfaces gráficas com o usuário. O intuito da criação da interface gráfica é disponibilizar um ambiente familiar ao usuário para a obtenção dos resultados classificatórios das mastigações, que poderão ser coletadas em campo, via *pen-drive* ou cartão SD. O usuário de posse destes dados poderá utilizar a interface e obter a resposta de forma simples e intuitiva.

6.1 DESENVOLVENDO UMA INTERFACE UTILIZANDO A *GUIDE*

Para realizar a construção da interface gráfica, é necessário primeiramente iniciar o *software* Matlab. Feito isso, digita-se no *prompt* a função "*Guide*", assim o programa irá apresentar a seguinte caixa de opções, como mostra a Figura 38 exibe a tela inicial da ferramenta *GUIDE* do Matlab.

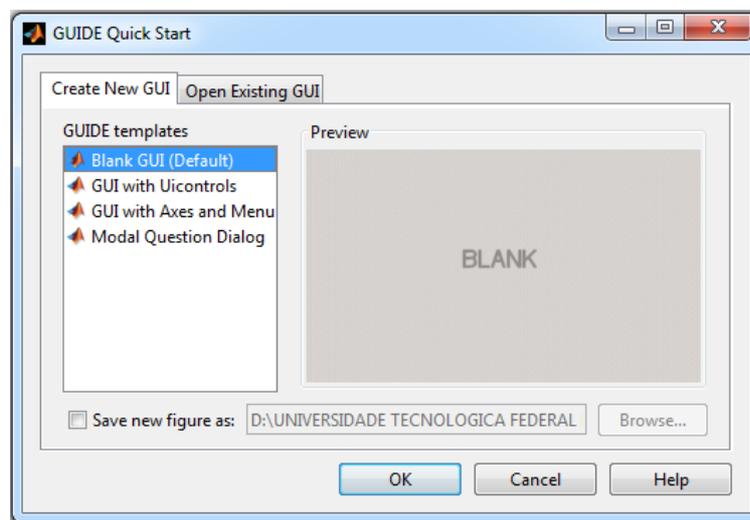


Figura 38: Inicialização da *GUIDE*.
Fonte: Autoria Própria.

Posteriormente, escolhe-se a opção "*Blank Gui (Default)*" e no ambiente mostrado pela Figura 39 são configurados os elementos que serão visíveis ao usuário.

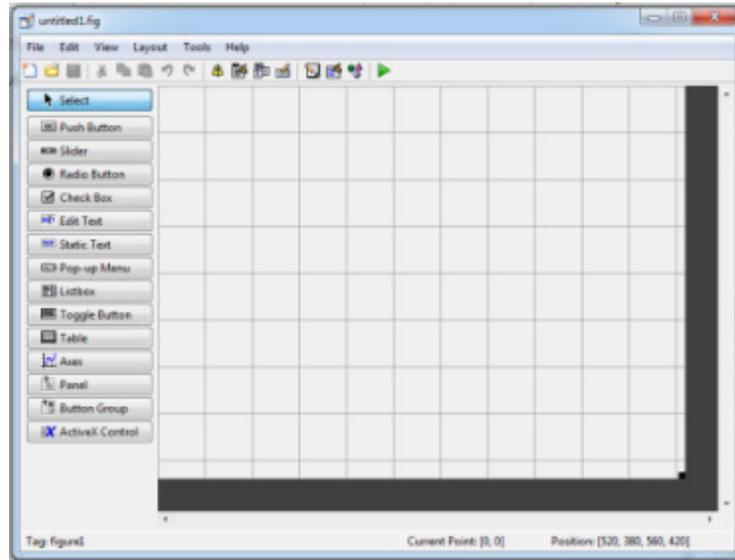


Figura 39: Tela inicial do ambiente gráfico.
Fonte: Autoria Própria.

Todo elemento adicionado à interface realizará um retorno de chamada (*callback*) quando acionado, ou seja, caso um botão for adicionado ao projeto, quando o usuário clicar em tal botão, um trecho de código será executado. Este trecho de código é escrito em um arquivo .m padrão do Matlab mas com delimitações para cada elemento. A Figura 40 ilustra a criação da interface gráfica para facilitar o uso da rede neural artificial.

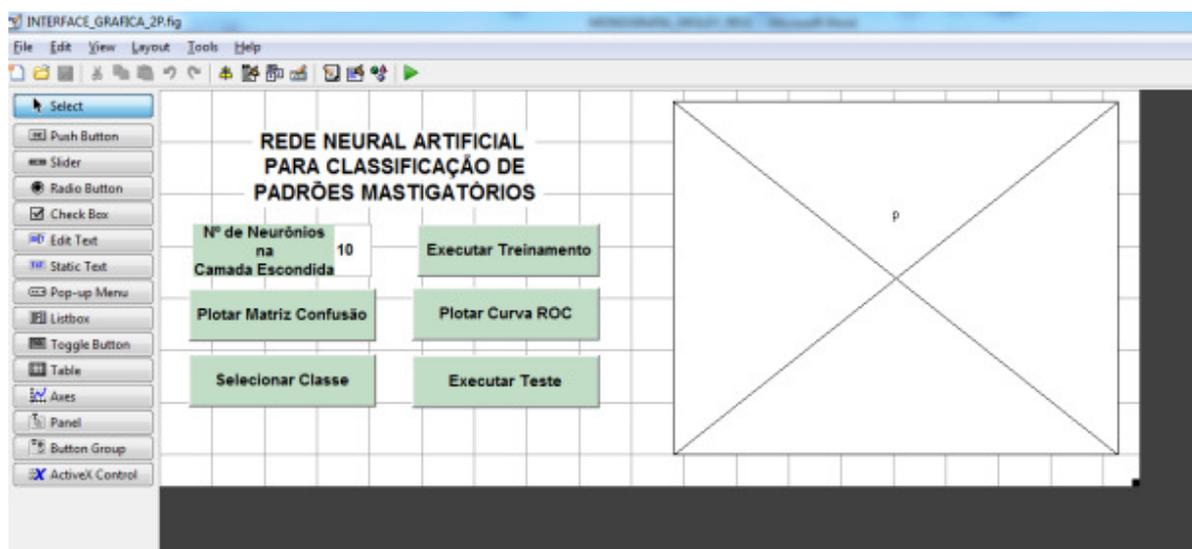


Figura 40: Criação da interface gráfica do usuário.
Fonte: Autoria Própria.

Na interface gráfica do usuário, pode-se realizar a criação da RNA para classificação dos padrões mastigatórios, o treinamento, teste e a visualização do

formato da rede. Após a realização destes passos, podem-se apresentar os gráficos de desempenho do treinamento, além da matriz confusão.

A figura 41 ilustra o modo de exibição da interface gráfica do usuário. O modo de operação é simples. Inicialmente é indicada a quantidade de neurônios na camada oculta que o usuário utilizará para realizar o treinamento da rede neural artificial. O próximo passo é realizar o treinamento da rede neural. Com a RNA treinada é possível traçar a curva ROC e exibir a matriz confusão, para analisar a resposta da rede em relação à classificação dos padrões mastigatórios.

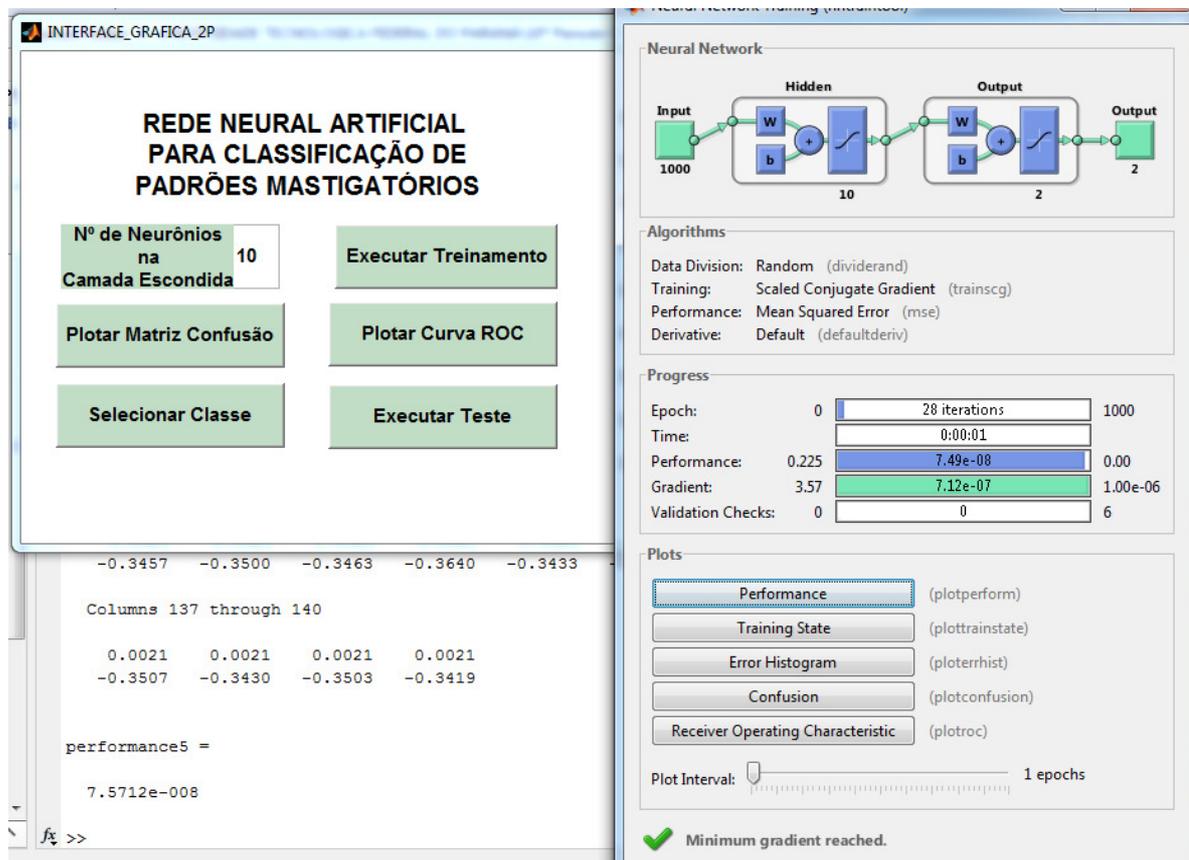


Figura 41: Parametrização da interface gráfica do usuário.
Fonte: Autoria Própria.

A Figura 42 ilustra a exibição da matriz confusão, onde basta clicar em Plotar Matriz Confusão para a interface gráfica gerar a figura.

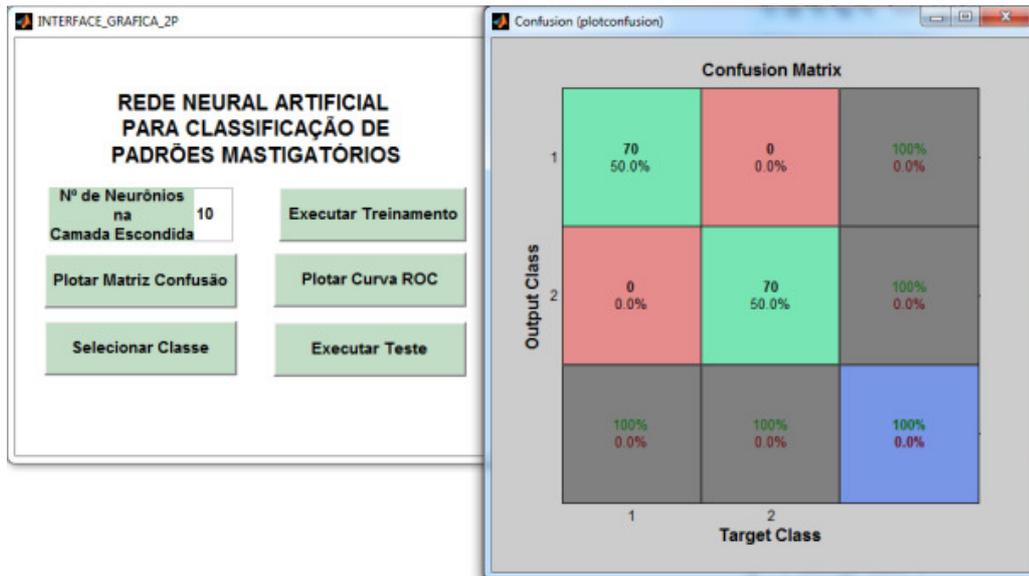


Figura 42: Plotando a matriz confusão.
Fonte: Autoria Própria.

Do mesmo modo, para exibir a curva ROC, basta clicar em Plotar Curva ROC, a Figura 43 ilustra a curva ROC para a RNA de classificação de dois padrões mastigatórios.

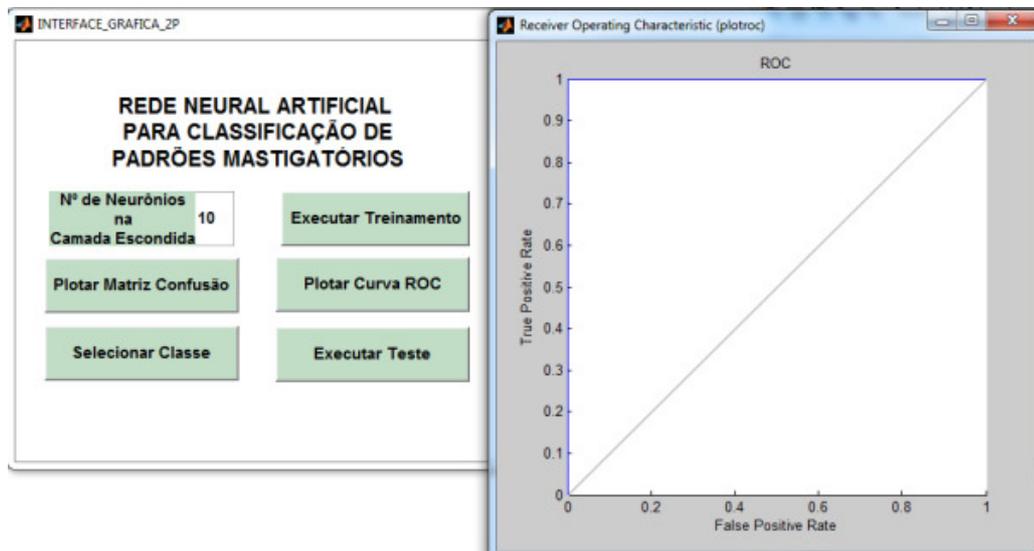


Figura 43: Plotando a curva ROC.
Fonte: Autoria Própria.

Uma vez que a RNA tenha sido treinada, para o usuário classificar um vetor contendo dados de um dos padrões treinados, basta selecionar a opção Selecionar Classe. A Figura 44 exibe a interface para o usuário selecionar o arquivo contendo os dados a serem classificados. Estes dados podem estar em qualquer diretório ou subdiretório. Esta é uma vantagem, pois é possível que o usuário traga dados de campo para realizar a classificação.

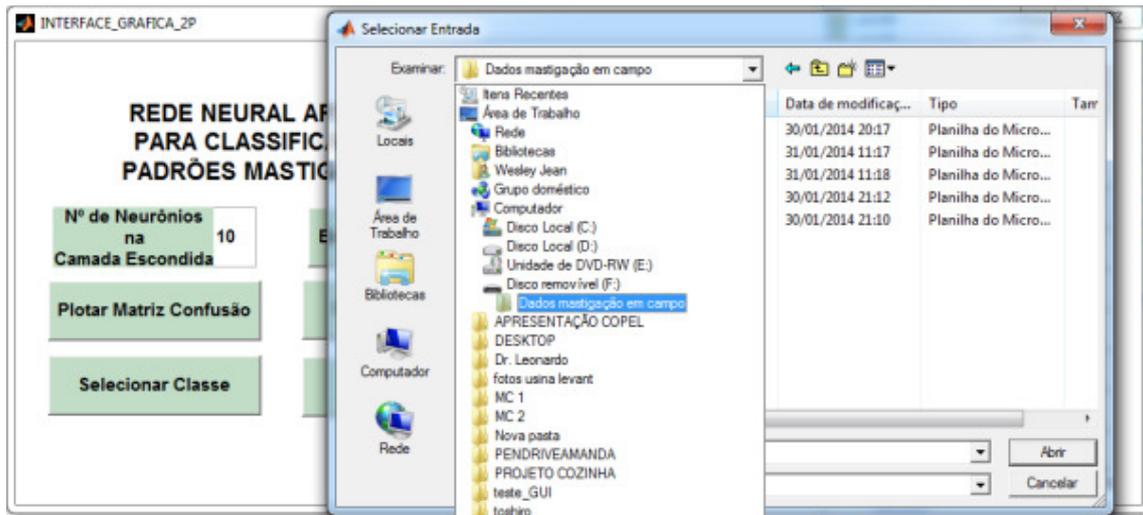


Figura 44: Escolha de entradas para realizar o treinamento da RNA via interface gráfica.
Fonte: Autoria Própria.

Após a escolha do arquivo contendo os dados a serem classificados, o software faz a exibição da forma de onda, conforme é ilustrado na Figura 45. Este comprimento de onda é um sinal correspondente a 1 segundo de simulação de mastigação, ou seja, um vetor de mil pontos. Este vetor é enviado como entrada para a RNA classificar.

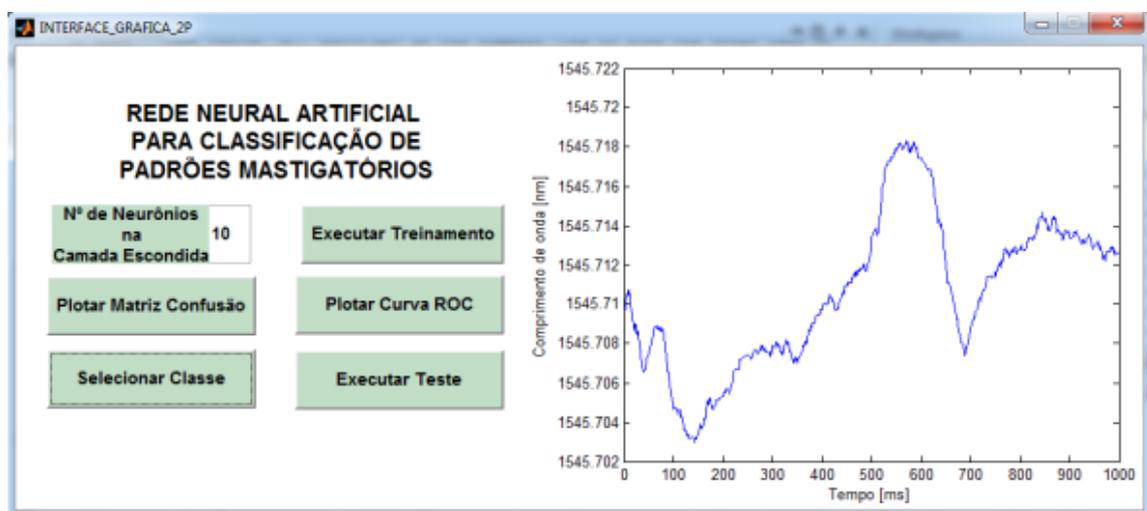


Figura 45: Visualização do comprimento de onda que será utilizado como entrada para teste.
Fonte: Autoria Própria.

Após a escolha do padrão a ser classificado, basta clicar em Executar Teste, que a RNA realizará a classificação do padrão. Após a execução da classificação, é exibido um gráfico contendo os resultados de classificação onde o sinal mais próximo da unidade é o sinal correspondente ao padrão lido na entrada. A Figura 46 exibe o resultado para um padrão sob análise correspondente a Plasticina

A. Observa-se que a RNA o classifica corretamente. Destaca-se que esta RNA foi treinada para classificar dois padrões e foram utilizados 10 neurônios na camada oculta.

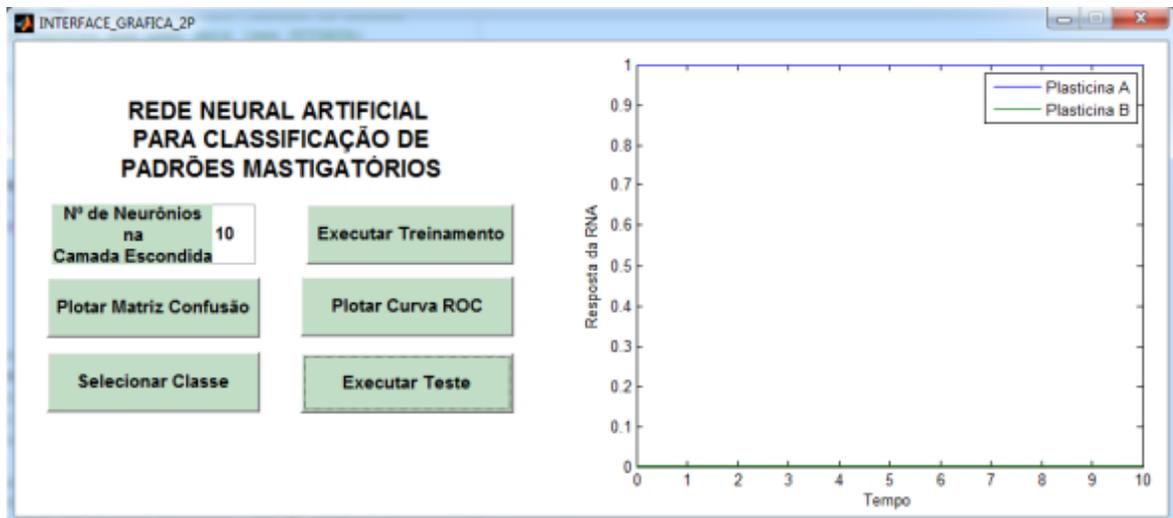


Figura 46: Resposta do teste de classificação de padrões utilizando a interface gráfica.
Fonte: Autoria Própria.

Caso o arquivo contenha dados referentes à Plasticina B, a Figura 47 exibe o resultado de classificação da RNA. Observa-se que o padrão foi corretamente classificado. Novamente esta rede foi treinada para classificar dois padrões.

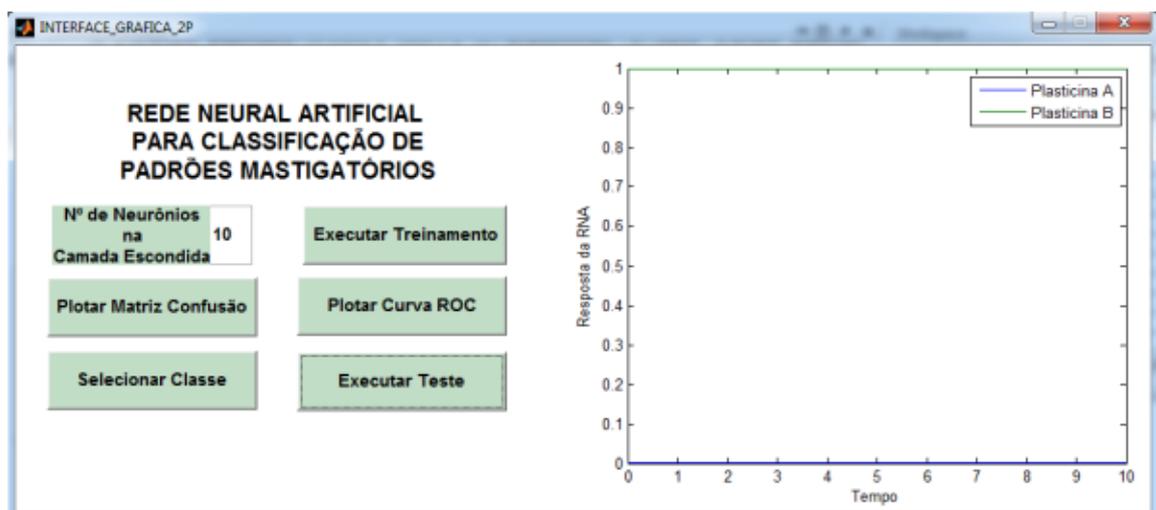


Figura 47: Resposta do teste de classificação de padrões utilizando a interface gráfica.
Fonte: Autoria Própria.

Utilizando a GUI para a Rede Neural Artificial de classificação dos cinco padrões mastigatórios, a resposta encontrada não foi satisfatória como para as duas plasticinas. Como é de se esperar, o aumento do número de classes impacta na

eficiência da RNA em classificá-las. Para cinco padrões mastigatórios, a classificação apresentou grande variação no desempenho. Em alguns casos, a rede classificou erroneamente o sinal.

A Figura 48 mostra o resultado da classificação para uma entrada com um padrão mastigatório de aveia. No treinamento de ambas as redes foram empregados 35 neurônios na camada oculta.

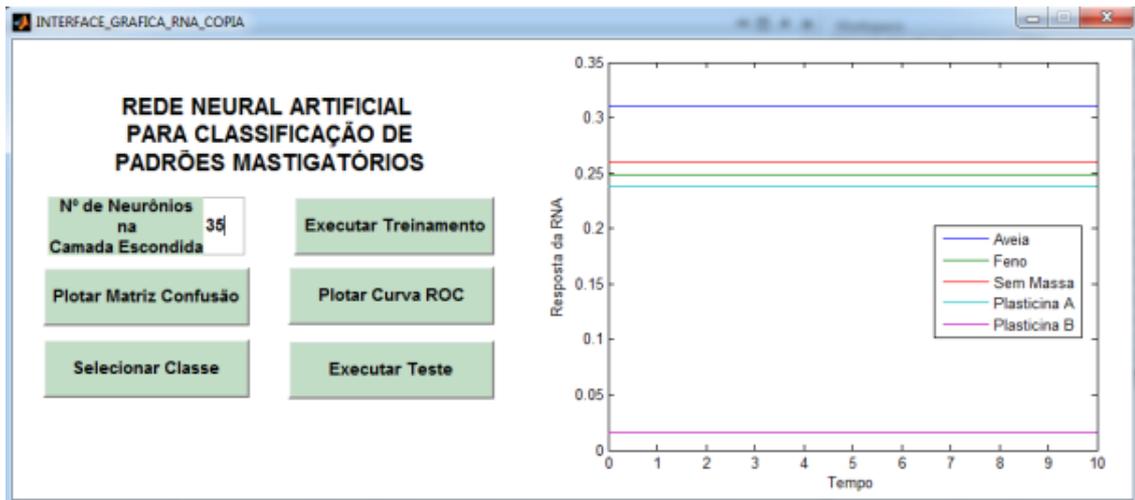


Figura 48: Resposta do teste de classificação de cinco padrões mastigatórios.
Fonte: Autoria Própria.

Pode-se observar que o sinal mais próximo da unidade é o correspondente ao sinal de entrada. Apesar de a rede neural ter classificado corretamente, estando a linha azul a mais próxima da unidade, pode-se notar que a rede neural teve dificuldade na separação dos demais padrões. Os demais padrões, idealmente deveriam estar próximos do valor 0.

7 CONCLUSÕES

Tratando das redes neurais elaboradas neste trabalho, pode-se dizer que os sinais encontrados durante as aquisições da mastigação com duas plasticinas apresentaram um padrão bem definido, o que possibilitou o uso das redes neurais. Os testes de dados das redes neurais para parâmetros de sinais apresentaram resultados satisfatórios, pois os resultados apresentados através das matrizes de confusão mostram que o desempenho geral da rede alcançou 100% de acerto para os testes realizados, tornando possível a identificação dos dois tipos de sinais. Já os sinais encontrados durante as aquisições da mastigação com feno de Tifton e aveia recém colhida apresentaram um padrão pouco definido, isto impactou no resultado final da rede neural artificial, apresentando uma variação na resposta da classificação dos padrões.

Isto confirma que a rede neural é uma ferramenta que pode contribuir para a classificação de padrões. Porém, para os casos estudados, necessita de um maior aprofundamento em como se pode aumentar a eficiência na classificação dos padrões para um cenário com diversos padrões a serem classificados. Isso possibilita o desenvolvimento de trabalhos futuros, onde poderá abranger também a verificação de outras topologias de redes neurais e outras funções de ativação.

A partir de ensaios *in vitro* pode-se ter uma noção da viabilidade do uso de redes neurais para a classificação de padrões de mastigação. Entretanto, para se validar, efetivamente o estudo, se faz necessária a realização de testes *in vivo*. Estes testes fornecerão informações reais sobre os padrões mastigatórios e diversos fatores reais, intrínsecos ao processo mastigatório, serão incluídos. Assim, erros inseridos pela simulação manual do processo mastigatório serão eliminados.

Os testes e ensaios *in vivo* não foram realizados no decorrer deste trabalho devido ao fato que, para os testes *in vivo*, é necessária a submissão do projeto para comissão de ética, pois envolve procedimentos cirúrgicos e tal processo pode demorar meses. Outra questão é que o campus não dispõe de animais vivos e de um veterinário, ou profissional capacitado, para realizar a cirurgia.

Para trabalhos futuros, também é sugerido um estudo da aplicação de Árvores de Decisão para a classificação de padrões mastigatórios para tentar diminuir a variação encontrada nas respostas da rede neural de classificação dos

cinco padrões mastigatórios. Outra opção para se investigar ainda utilizando RNAs é realizar um condicionamento dos sinais. Como sugestão, pode-se investigar o resultado do uso da RNA com sinais de média zero. Outra modificação a ser realizada é a ampliação dos sinais, visto que a variação destes se dá em um intervalo muito pequeno.

Uma das dificuldades encontradas no decorrer do trabalho foi tentar melhorar o desempenho da rede neural treinada para cinco classes, uma vez que os sinais do conjunto de vetores de entrada foram tratados novamente, procurando utilizar pontos mais definidos, contudo, os resultados obtidos foram os mesmos. Como é difícil se definir o que a rede neural está aprendendo, não se pode afirmar com precisão, pelo menos com os resultados até o momento obtidos, qual foi o real fator que influenciou na classificação errônea dos padrões para uma rede treinada para cinco classes. Uma hipótese é que a rede esteja aprendendo o valor médio dos sinais que, em alguns casos, é bastante similar.

Outra dificuldade encontrada foi o fato de o trabalho se tratar de um tema não abordado no curso de Engenharia Elétrica, o que exigiu maior tempo para os estudos bibliográficos, não só para o tema de Inteligência Artificial como também para o tema de nutrição animal. Em última análise, vale ratificar que apesar das dificuldades encontradas, os objetivos do trabalho foram alcançados.

8 REFERÊNCIAS

AGRICULTURA, Ministério D. **Ministério da Agricultura**, 2013. Disponível em: <<http://www.agricultura.gov.br/animal/especies/caprinos-e-ovinos>>. Acesso em: 17 Novembro 2013.

ALVAREZ, Ana B.; LUQUE, Baldomero. **Rede Neural de Kohonen e Outras Técnicas para Treinamento**. 2003. Trabalho de Conclusão de Curso - Universidade Estadual de Campinas, Campinas, 2003.

ASSMANN, Tangriani S.; ASSMANN, Alceu L.; SOARES, André B. **Uso do solo em sistemas conservacionistas para o cultivo de pastagens**. 2013. Resumo da III Reunião Paranaense de Ciência do Solo, Londrina, 2013.

ATUAL, Mecatrônica. **Mecatrônica Atual**, 2013. Disponível em: <<http://www.mecatronicaatual.com.br/educacao/2334-reconhecimento-de-trajetria-com-redes-neurais-2>>. Acesso em: 18 Dezembro 2013.

BARRETO, Flávia M. **Esofagostomia Experimental em Caprinos, com Cânula Definitiva e Removível**. 2007. Dissertação de mestrado - Universidade Federal do Piauí, Teresina, 2007.

BARRETO, JORGE M. **INTELIGÊNCIA ARTIFICIAL NO LIMIAR DO SÉCULO**. 2^a. ed. FLORIANÓPOLIS: DUPLIC, 1999.

BARROS, Carina Simionato de; SILVA, Cláudio José Araújo da; DITTRIC, João Ricardo; MONTEIRO, Alda Lúcia Gomes. Bocados de Caprinos na Pastagem de Aruana. **Revista do Conselho de Medicina Veterinária do Paraná**, Curitiba, v. 20, p. 20-20, set. 2006.

CARVALHO, André C. D.; BRAGA, Antonio de Pádua; LUDERMIR, Teresa. **Fundamentos das Redes Neurais Artificiais**. Rio de Janeiro: DCC/IM, 1998.

CARVALHO, Paulo César de Faccio; TRINDADE, Julio Kuhn da; MEZZALIRA, Jean Carlos. Do bocado ao pastoreio de precisão: Compreendendo a interface planta-animal para explorar a multi-funcionalidade das pastagens. **Revista Brasileira de Zootecnia**, Porto Alegre, v. 38, p. 109-122, 2009.

DEMUTH, Howard; BEALE, Mark; HAGAN, Martin. MathWorks Accelerating the pace of engineering and science. Disponível em: <www.mathworks.com>. Acesso em: 13 ago. 2013.

FERREIRA, Renan Utida; ROCHA, Adson Ferreira da; JÚNIOR, Carlos Alberto Casão; BORGES, Geovany Araujo. **Reconhecimento de padrões de sinais de EMG para controle de prótese de perna**. 2005. Artigo - Departamento de Engenharia Elétrica - CEFET, Brasília, 2005.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2ª. ed. Porto Alegre: Bookman, 2001.

JR., Oswaldo L.; COSTA, Eduard M. **Redes Neurais: Fundamentos e Aplicações**. Única Edição. Rio de Janeiro: Ciência Moderna Ltda, 2007.

JÚNIOR, Cairo L. N. **Inteligência Artificial em Controle e Automação**. 1ª. ed. São Paulo: Edgard Blucher Ltda, 2000.

LOPES, Diego; FARIAS, Claudia; SILVA, Ivan; BARBOSA, João. Utilização de Redes Neurais Artificiais na Classificação de Padrões de Sinais Ultrassônicos. **CONNEPI**, Belém, 2009.

MEZZALIRA, Jean Carlos; BONNET, Oliver; TRINDADE, Júlio; BREMM, Carolina; GENRO, Teresa; SILVA, Luiz da. **O som do pastejo: desenvolvimento da bioacústica para descrever e quantificar o processo ingestivo nos ambientes pastoris**. 2012. Artigo de revista - Revista Brasileira de Zootecnia, Porto Alegre, 2012.

NOVAIS, Acassio; NOVAIS, Fábio; ARAUJO, Ramon; NEVES, Thales. **Redes Neurais Artificiais**. 2009. Trabalho de Conclusão de Curso - Universidade Federal da Bahia, Salvador, 2009.

SANTOS, Nailson L. **AVALIAÇÃO DO CAPIM TANZÂNIA MANEJADO COM DIFERENTES IAF RESIDUAIS**. 2009. Dissertação de mestrado - Universidade Estadual Paulista, Jaboticabal, São Paulo, 2009.

STEHMAN, Stephen V. **Remote Sensing of Environment "Selecting and interpreting measures of thematic classification accuracy"**. Artigo - University of New England, Armidale, Australia, 1997.

TORTORELLI, Gabriela; PADILHA, João; MENDES, Gandara; GREGORY, Lilian. Atendimento a Criatórios de Bovinos e Pequenos Ruminantes. **Revista Cultura e Extensão USP**, São Paulo, v. 8, Julho 2009.

TRINDADE, Júlio K. D. **Comportamento e Consumo de Forragem de Bovinos de Corte em Pastagem Natural Complexa**. 2011. Dissertação de mestrado - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

VIRTUAL, Capril. Capril Virtual Portal Especializado em Ovinos e Caprinos. **Capril Virtual Portal Especializado em Ovinos e Caprinos**, 2013. Disponível em: <<http://www.caprilvirtual.com.br/>>. Acesso em: 17 Novembro 2013.

WOSNIAK, Carla; CARDOSO, Rafael; HILL, João; SILVEIRA, André; SOUZA, Kleiton; SILVA, Jean Carlos Cardozo da; ASSMANN, Tangriani; KALINOWSKI, Hypolito; SILVA, Wesley Jean da. **Determination of Chewing Patterns in Goats using Fiber Bragg**. In: 22nd International Conference on Optical Fiber Sensors (OFS-22), 2012. Beijing: Proceedings of SPIE. Bellingham WA, USA: Society of Photo-Optical Instrumentation Engineers (SPIE), 2012. v. 8421. 2012. p. 1-4.

APÊNDICE

Neste apêndice estão evidenciados trechos do código criado para a elaboração da rede neural artificial de classificação dos padrões mastigatórios das duas plasticinas.

Os códigos das Listagens 1 e 2 ilustram a forma de separar apenas o trecho da simulação utilizado para a RNA.

```

clc;
clear all;
importa_dados('Mastigacao_Massa1.xlsx');

pos_im1=4e4; %posicao inicial
pos_fm1=12e4; %posicao final

t_2=zeros(1,pos_fm1-pos_im1);
cdo_2=zeros(1,pos_fm1-pos_im1);

for i=1:(pos_fm1-pos_im1)
    t_2(i)=tm1(pos_im1+i);
    cdo_2(i)=cdo1(pos_im1+i);
end

```

Listagem 1: Criação do gráfico do parâmetro de sinal referente à mastigação da Plasticina A.

```

importa_dados('Mastigacao_Massa2.xlsx');

pos_im2=2e4; %posicao inicial
pos_fm2=10e4; %posicao fina

t_4=zeros(1,pos_fm2-pos_im2);
cdo_4=zeros(1,pos_fm2-pos_im2);

for i=1:(pos_fm2-pos_im2)
    t_4(i)=tm2(pos_im2+i);
    cdo_4(i)=cdo2(pos_im2+i);
end

```

Listagem 2: Criação do gráfico do parâmetro de sinal referente à mastigação da Plasticina B.

A Listagem 3 mostra o código criado para a elaboração do primeiro vetor do conjunto de vetores de entrada da mastigação da plasticina A, onde cdo_2 trata-se do sinal da simulação com a plasticina A, com 80 vetores de 1000 pontos cada, partindo de cdo1 à cdo80. A Listagem 4 mostra o código criado para a elaboração do primeiro vetor do conjunto de vetores de entrada da mastigação da plasticina B,

onde `cdo_4` trata-se do sinal da simulação com a plasticina B, com 80 vetores de 1000 pontos cada, partindo de `cdo81` à `cdo160`.

```
% vetores Inputs Massa 1

k1=1000;           %comprimento
cdo1=zeros(1,k1); %vetor 1

for i=1:k1
    cdo1(i)=cdo_2(i);
end
```

Listagem 3: Criação do primeiro vetor do conjunto de vetores de entrada Plasticina A.

```
% vetores Inputs Massa 2

k1=1000;           %comprimento
cdo81=zeros(1,k1); %vetor 81

for i=1:k1
    cdo81(i)=cdo_4(i);
end
```

Listagem 4: Criação do primeiro vetor do conjunto de vetores de entrada Plasticina B.

As Listagens 5 e 6 ilustram fragmentos do código utilizado para a criação do conjunto de vetores alvo.

```
%%% Inputs

P = [cdo1; cdo2; cdo3; cdo4; cdo5; cdo6; cdo7; cdo8; cdo9; cdo10; ...

%%% Targets

T = [0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 ...
```

Listagem 5: Criação do conjunto de vetores alvo da Plasticina A.

```
... cdo81; cdo82; cdo83; cdo84; cdo85; cdo86; cdo87; cdo88; cdo89; cdo90; ...
... 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 ...
```

Listagem 6: Criação do conjunto de vetores alvo da Plasticina B.

A Listagem 7 mostra este código, o qual mostra os passos para a realização da rede neural artificial manualmente e utilizando o *workspace* do Matlab. A interface gráfica de usuário (GUI) utilizou este *script* para a formulação da rede neural artificial para a classificação dos padrões mastigatórios das duas plasticinas.

```
% Solve a Pattern Recognition Problem with a Neural Network

inputs = P;
targets = T;

% Create a Pattern Recognition Network
hiddenLayerSize = 10;
net = patternnet(hiddenLayerSize);

% Setup Division of Data for Training, Validation, Testing
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Train the Network
[net,tr] = train(net,inputs,targets);

% Test the Network
outputs = net(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)

% View the Network
view(net)

% Plots
figure, plotconfusion(targets,outputs)
figure, plotroc(targets,outputs)
```

Listagem 7: Script gerado por NPRTOOL.

APÊNDICE B

Neste apêndice estão evidenciados trechos do código criado para a elaboração da rede neural artificial de classificação dos cinco padrões mastigatórios.

Os códigos das Listagens 8 ilustram a forma de separar apenas o trecho da simulação utilizado para a RNA.

```

IMPORT_AVEIA('AVEIA.xlsx');

pos_im1=4e4; %posicao inicial
pos_fm1=12e4; %posicao fina

t_2=zeros(1,pos_fm1-pos_im1);
cdo_2=zeros(1,pos_fm1-pos_im1);

for i=1:(pos_fm1-pos_im1)
    t_2(i)=tem_A(pos_im1+i);
    cdo_2(i)=cdo_A(pos_im1+i);
end

```

(a)

```

IMPORT_FENO('FENO.xlsx');

pos_im1=4e4; %posicao inicial
pos_fm1=12e4; %posicao fina

t_4=zeros(1,pos_fm1-pos_im1);
cdo_4=zeros(1,pos_fm1-pos_im1);

for i=1:(pos_fm1-pos_im1)
    t_4(i)=tem_F(pos_im1+i);
    cdo_4(i)=cdo_F(pos_im1+i);
end

```

(b)

```

IMPORT_NOMASTIG('NOMASTIG.xlsx');

pos_im1=4e4; %posicao inicial
pos_fm1=12e4; %posicao final

t_6=zeros(1,pos_fm1-pos_im1);
cdo_6=zeros(1,pos_fm1-pos_im1);

for i=1:(pos_fm1-pos_im1)
    t_6(i)=tem_M(pos_im1+i);
    cdo_6(i)=cdo_M(pos_im1+i);
end

```

(c)

```

IMPORT_MASSA1 ('MASSA1.xlsx');

pos_im1=4e4; %posicao inicial
pos_fm1=12e4; %posicao fina

t_8=zeros(1,pos_fm1-pos_im1);
cdo_8=zeros(1,pos_fm1-pos_im1);

for i=1:(pos_fm1-pos_im1)
    t_8(i)=tem_M1(pos_im1+i);
    cdo_8(i)=cdo_M1(pos_im1+i);
end

```

(d)

```

IMPORT_MASSA2 ('MASSA2.xlsx');

pos_im1=2e4; %posicao inicial
pos_fm1=10e4; %posicao fina

t_10=zeros(1,pos_fm1-pos_im1);
cdo_10=zeros(1,pos_fm1-pos_im1);

for i=1:(pos_fm1-pos_im1)
    t_10(i)=tm2(pos_im1+i);
    cdo_10(i)=cdom2(pos_im1+i);
end

```

(e)

Listagem 8: Criação do gráfico do parâmetro de sinal referente à: (a) mastigação da aveia; (b) mastigação do feno, (c) mastigação sem massa, (d) mastigação plasticina A, (e) mastigação plasticina B.

A Listagem 9 mostra os códigos criados para a elaboração do primeiro vetor dos conjuntos de vetores de entrada das mastigações. Onde cdo_2 trata-se do sinal da simulação com aveia, com 80 vetores de 1000 pontos cada, partindo de cdo1 à cdo80. Tem-se cdo_4 que trata-se do sinal de simulação com feno, com 80 vetores de 1000 pontos cada, partindo de cdo81 à cdo160. O vetor cdo_6 se trata do sinal da simulação sem massa, com 80 vetores de 1000 pontos cada, partindo de cdo161 à cdo240. Já o vetor cdo_8 se trata do sinal da simulação com a plasticina A, com 80 vetores de 1000 pontos cada, partindo de cdo241 à cdo320. E por fim, o vetor cdo_10 que trata-se do sinal de simulação com a plasticina B, com 80 vetores de 1000 pontos cada, partindo de cdo321 à cdo400.

```

% vetores Inputs

k1=1000; %comprim.
cdo1=zeros(1,k1); %vetor 1

for i=1:k1
    cdo1(i)=cdo_2(i);
end

```

(a)

```

% vetores Inputs

k81=1000; %comprim.
cdo81=zeros(1,k81); %vetor 81

for i=1:k81
    cdo81(i)=cdo_4(i);
end

```

(b)

```

% vetores Inputs

k161=1000;           %comprimento
cdo161=zeros(1,k161); %vetor 111

for i=1:k161
    cdo161(i)=cdo_6(i);
end

```

(c)

```

% vetores Inputs

k241=1000;           %comprimento
cdo241=zeros(1,k241); %vetor 141

for i=1:k241
    cdo241(i)=cdo_8(i);
end

```

(d)

```

% vetores Inputs

k321=1000;           %comprimento
cdo321=zeros(1,k321); %vetor 121

for i=1:k321
    cdo321(i)=cdo_10(i);
end

```

(e)

Listagem 9: Criação dos primeiros vetores dos conjuntos de vetores de entrada.

(a) mastigação da aveia; (b) mastigação do feno, (c) mastigação sem massa, (d) mastigação plasticina A, (e) mastigação plasticina B.

A Listagem 10 ilustra parte do código onde foram definidos os valores alvo para cada valor de entrada.

```

%%% Inputs

x = [cdo1; cdo2; cdo3; cdo4; cdo5; cdo6; cdo7; cdo8; cdo9; ...

%%% Targets

y = [0 0 0 0 1; 0 0 0 0 1; 0 0 0 0 1; 0 0 0 0 1; 0 0 0 0 1; ...

P=x';

T=y';

```

Listagem 10: Criação do conjunto de vetores alvo.

A Listagem 11 mostra o código que apresenta os passos para a realização da rede neural artificial para classificação dos cinco padrões mastigatórios. A interface gráfica de usuário (GUI) utilizou-se deste *script* para a formulação da rede neural artificial.

```
% Solve a Pattern Recognition Problem with a Neural Network
%
% This script assumes these variables are defined:
%
% P - input data.
% T - target data.

inputs = P;
targets = T;

% Create a Pattern Recognition Network
hiddenLayerSize = 35;
net = patternnet(hiddenLayerSize);

% Setup Division of Data for Training, Validation, Testing
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Train the Network
[net,tr] = train(net,inputs,targets);

% Test the Network
outputs = net(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)

% View the Network
view(net)

% Plots
% Uncomment these lines to enable various plots.
figure, plotconfusion(targets,outputs)
figure, plotroc(targets,outputs)
```

Listagem 11: Script gerado por NPRTOOL.