

UNIVERSIDADE FEDERAL DE GOIÁS
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA
E DE COMPUTAÇÃO

**DESENVOLVIMENTO DE TECNOLOGIA BASEADA
EM REDES NEURAIS ARTIFICIAIS PARA
RECONHECIMENTO DE GESTOS DA LÍNGUA DE
SINAIS**

Brunna Carolinne Rocha Silva

[UFG] & [EMC]
[Goiânia - Goiás - Brasil]
12 de junho de 2018

**TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR
VERSÕES ELETRÔNICAS DE TESES E DISSERTAÇÕES
NA BIBLIOTECA DIGITAL DA UFG**

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do material bibliográfico: ☒ **Dissertação** ☐ **Tese**

2. Identificação da Tese ou Dissertação:


Nome completo do autor: Brunna Carolinne Rocha Silva

Título do trabalho: Desenvolvimento de Tecnologia Baseada em Redes Neurais Artificiais Para Reconhecimento de Gestos da Língua de Sinais

3. Informações de acesso ao documento:

Concorda com a liberação total do documento ☒ SIM ☐ NÃO¹

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF da tese ou dissertação.



Assinatura do(a) autor(a)²

Ciente e de acordo:



Assinatura do(a) orientador(a)²

Data: 04 / 06 / 2018

¹ Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

² A assinatura deve ser escaneada.

UNIVERSIDADE FEDERAL DE GOIÁS
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA
E DE COMPUTAÇÃO

**DESENVOLVIMENTO DE TECNOLOGIA BASEADA
EM REDES NEURAIS ARTIFICIAIS PARA
RECONHECIMENTO DE GESTOS DA LÍNGUA DE
SINAIS**

Brunna Carolinne Rocha Silva

Dissertação apresentada à Banca Examinadora como exigência parcial para a obtenção do título de Mestre em Engenharia Elétrica e de Computação pela Universidade Federal de Goiás (UFG), Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), sob a orientação do Prof. Dr. Wesley Pacheco Calixto

[UFG] & [EMC]
[Goiânia - Goiás - Brasil]
12 de junho de 2018

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Silva, Brunna Carolinne Rocha
Desenvolvimento de Tecnologia Baseada em Redes Neurais
Artificiais Para Reconhecimento de Gestos da Língua de Sinais
[manuscrito] / Brunna Carolinne Rocha Silva. - 2018.
103 f.

Orientador: Prof. Wesley Pacheco Calixto.
Dissertação (Mestrado) - Universidade Federal de Goiás, Escola
de Engenharia Elétrica, Mecânica e de Computação (EMC), Programa
de Pós-Graduação em Engenharia Elétrica e de Computação, Goiânia,
2018.

Inclui siglas, lista de figuras, lista de tabelas.

1. Língua de Sinais. 2. Tecnologia para reconhecimento. 3.
Reconhecimento de padrões. 4. Redes neurais artificiais. I. Calixto,
Wesley Pacheco , orient. II. Título.

CDU 621.3



Ata de Defesa de Dissertação de Mestrado

Ata da sessão de julgamento da Dissertação de Mestrado em Engenharia Elétrica e de Computação, área de concentração Engenharia de Computação, da candidata **Brunna Carolinne Rocha Silva** realizada em 06 de abril de 2018.

Aos seis dias do mês de abril de dois mil e dezoito, às 14:00 horas, na sala Caryocar Brasiliensis nas dependências da Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), Universidade Federal de Goiás (UFG), reuniram-se os seguintes membros da Comissão Examinadora designada pela Coordenadoria do Programa de Pós-graduação em Engenharia Elétrica e de Computação: os Doutores Wesley Pacheco Calixto - (EMC/UFG), Marco Hiroshi Naka - (ENG/IFMS), Prof^ª. Dr^ª. Juliana Guimarães Faria - (LIBRAS/UFG), Ruberley Rodrigues de Souza - (FIS-IFG), Carlos Fernando da Silva Ramos - (IPPorto/Portugal) e Gelson da Cruz Júnior - (EMC/UFG), para julgar a Dissertação de Mestrado de **Brunna Carolinne Rocha Silva**, intitulada **“Desenvolvimento de tecnologia baseada em redes neurais artificiais para reconhecimento de gestos da língua de sinais”**, apresentada pela candidata como parte dos requisitos necessários à obtenção do grau de Mestre, em conformidade com a regulamentação em vigor. O Professor Doutor Wesley Pacheco Calixto, Presidente da Comissão, abriu a sessão e apresentou a candidata que discorreu sobre seu trabalho, após o que, foi arguida pelos membros da Comissão na seguinte ordem: Marco Hiroshi Naka, Carlos Fernando da Silva Ramos, Juliana Guimarães Faria, Ruberley Rodrigues de Souza e Gelson da Cruz Júnior. A parte pública da sessão foi então encerrada e a Comissão Examinadora reuniu-se em sessão reservada para deliberar. A Comissão julgou então que a candidata, tendo demonstrado conhecimento suficiente, capacidade de sistematização e argumentação sobre o tema de sua Dissertação, foi considerada **aprovada** e deve satisfazer as exigências listadas na Folha de Modificação, em anexo a esta Ata, no prazo máximo de 60 dias, ficando o professor orientador responsável por atestar o cumprimento destas exigências. Os membros da Comissão Examinadora descreveram as justificativas para tal avaliação em suas respectivas Folhas de Avaliação, anexas a esta Ata. Nada mais havendo a tratar, o presidente da Comissão declarou encerrada a sessão. Nos termos do Regulamento Geral dos Cursos de Pós-graduação desta Universidade, a presente Ata foi lavrada, lida e, julgada conforme, segue assinada pelos membros da Comissão supracitados e pela candidata. Goiânia, 06 de abril de 2018.

Comissão Examinadora designada:

Prof. Dr. Wesley Pacheco Calixto - Orientador (EMC/UFG)

(Avaliação: Aprovada)

Prof. Dr. Marco Hiroshi Naka - Membro Externo (ENG/IFMS)

(Avaliação: Aprova)

Prof^ª. Dr^ª. Juliana Guimarães Faria - Membro Externo (LIBRAS/UFG)

(Avaliação: Aprovada)

Prof. Dr. Ruberley Rodrigues de Souza - Membro Externo (FIS/IFG)

(Avaliação: aprov.)

Prof. Dr. Carlos Fernando da Silva Ramos - Membro Externo (IPPorto/Portugal)

(Avaliação: AP)

Prof. Dr. Prof. Gelson da Cruz Júnior - Membro Interno (EMC/UFG)

(Avaliação: aprovada)

Candidata:

Brunna Carolinne Rocha Silva

*“Never walk on the traveled path because it only leads where others
have been”.*

ALEXANDER GRAHAM BELL

A todos aqueles que deixam suas marcas no mundo.

A eles dedico este trabalho.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me dar paz e serenidade quando mais precisei.

Agradeço ao Prof. Wesley Pacheco Calixto que, com o seu grande apoio, dedicação, orientação e confiança, me ajudou a construir o caminho que percorri desde a idealização deste trabalho.

Agradeço, em especial, a minha querida mãe Roseli Gonçalves da Rocha e a minha querida avó Maria Gonçalves Rosa (in memoriam), que me apoiam desde os pequenos passos até aqueles que nem eu mesma acreditei. Também agradeço ao meu amigo e namorado Geovanne Pereira Furriel por todo o incentivo, carinho e por todas as noites de discussão e partilha de saberes e experiências.

Agradeço a empresa NC Neoprene por confiar no trabalho e confeccionar luva utilizada para construção do Protótipo P_4 .

Agradeço a todos os familiares, amigos e colegas que contribuíram para o término desta jornada.

RESUMO

O intuito deste trabalho é projetar, desenvolver e avaliar quatro dispositivos capazes de identificar configuração, orientação e movimento das mãos, verificando qual possui melhor desempenho para reconhecimento de gestos da língua de sinais. A metodologia parte da definição do leiaute e dos componentes de aquisição e processamento de dados, da construção da base de dados tratados para cada gesto a ser reconhecido e da validação dos dispositivos propostos. São coletados sinais de sensores de flexão, acelerômetros e giroscópios, posicionados diferentemente em cada dispositivo. O reconhecimento dos padrões de cada gesto é realizado utilizando redes neurais artificiais. Após treinada, validada e testada, a rede neural interligada aos dispositivos obtêm média de acerto de até 96,8%. O dispositivo validado oferece eficácia e eficiência para identificar gestos da língua de sinais e demonstra que o uso da abordagem sensorial é promissora.

DEVELOPMENT OF TECHNOLOGY BASED ON ARTIFICIAL NEURAL NETWORK FOR SIGN LANGUAGE GESTURE RECOGNITION

ABSTRACT

The purpose of this paper is to design, develop and evaluate four devices capable of identifying configuration, orientation and movement of the hands, verifying which one has better performance recognition of sign language gestures. The methodology starts from the definition of the layout and the components of data acquisition and processing, the construction of the database treated for each gesture to be recognized and validation of the proposed devices. Signs of flex sensors, accelerometers and gyroscopes are collected, positioned differently on each device. The recognition of the patterns of each gesture is performed using artificial neural networks. After being trained, validated and tested, the neural network interconnected to the devices obtain a hit rate of up to 96.8%. The validated device offers efficacy and efficiency to identify sign language gestures and demonstrates that the use of the sensory approach is promising.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE SÍMBOLOS

CAPÍTULO 1 INTRODUÇÃO 21

CAPÍTULO 2 LÍNGUA DE SINAIS 25

2.1 Comunicação dos surdos 25

2.1.1 Conceituação e legislação sobre a Língua Brasileira de Sinais 25

2.1.2 Comunicação na comunidade surda 26

2.2 Mitos da língua de sinais 27

2.2.1 Primeiro mito 28

2.2.2 Segundo mito 28

2.2.3 Terceiro mito 28

2.2.4 Quarto mito 28

2.2.5 Quinto mito 29

2.2.6 Sexto mito 29

2.3 Construção linguística da língua de sinais 29

2.4 Datilologia 31

2.5 A língua de sinais e datilologia pelo mundo 32

2.6 Considerações 33

CAPÍTULO 3 SISTEMA DE MANIPULAÇÃO DE DADOS E RE- CONHECIMENTO DE PADRÃO 35

3.1 Processamento de dados 35

3.2 Aquisição de dados, instrumentação e medidas 37

3.2.1 Sensores de flexão 37

3.2.2 Acelerômetro e giroscópio 38

3.2.3 Comunicação entre os dispositivos 41

3.3 Perceptron Múltiplas Camadas 43

3.3.1 Neurônio Artificial 44

3.3.2 Função de ativação 45

3.3.3	Modelo do Perceptron múltiplas camadas	47
3.3.4	Termo <i>Momentum</i>	51
3.4	Codificação de classes	53
3.5	Considerações	56
CAPÍTULO 4 METODOLOGIA		57
4.1	Leiaute do dispositivo	57
4.2	Construção dos dispositivos	58
4.3	Aquisição dos dados	62
4.4	Processamento dos dados	67
4.5	Validação	68
4.6	Considerações	69
CAPÍTULO 5 RESULTADOS		71
5.1	Leiaute, construção dos dispositivos e componentes	71
5.2	Construção da base de dados	74
5.3	Tratamento dos dados para a rede Perceptron múltiplas camadas	77
5.3.1	Parâmetros iniciais da rede Perceptron múltiplas camadas	80
5.3.2	Taxas de aprendizagem	80
5.3.3	Topologia da rede Perceptron múltiplas camadas	81
5.4	Validação dos resultados	83
5.5	Gestos dinâmico com mais de uma coleta no tempo	85
5.6	Comentários	87
CAPÍTULO 6 CONCLUSÃO		91
6.1	Contribuições do Trabalho	92
6.2	Sugestões para Trabalhos Futuros	93
REFERÊNCIAS BIBLIOGRÁFICAS		95

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Alfabeto manual	31
3.1 Diagrama simplificado do processo de reconhecimento de padrão.	35
3.2 Sensor de flexão.	38
3.3 Estrutura interna do acelerômetro.	39
3.4 Estrutura interna do giroscópio.	40
3.5 Unidades inerciais.	40
3.6 Ilustração do microcontrolador.	41
3.7 Esquema elétrico para conexão e utilização do protocolo I2C.	43
3.8 Sistema demultiplexador.	43
3.9 Neurônio artificial.	44
3.10 Funções de ativação: (a) degrau (3.1), (b) degrau bipolar (3.2), (c) linear (3.3), (d) logística (3.4) e (e) tangente hiperbólica (3.5).	45
3.11 Perceptron múltiplas camadas	47
3.12 Algoritmo <i>backpropagation</i> : (a) etapa <i>forward</i> e (b) etapa <i>backward</i>	49
3.13 Topologia do Perceptron múltiplas camadas.	49
3.14 Fluxograma de funcionamento da rede Perceptron múltiplas camadas.	54
4.1 Fluxograma para desenvolvimento de tecnologia para reconhecimento de gestos das língua de sinais.	58
4.2 Parâmetro fonológico da língua de sinais: ponto de articulação.	59
4.3 Parâmetros fonológicos da língua de sinais: (a) configuração de mão, (b) orientação e (c) movimento.	59
4.4 Protótipo P_1 : (a) leiaute e (b) diagrama de conexão.	60
4.5 Protótipo P_2 : (a) leiaute e (b) diagrama de conexão.	61
4.6 Protótipo P_3 : (a) leiaute e (b) diagrama de conexão.	61
4.7 Protótipo P_4 : (a) leiaute e (b) diagrama de conexão.	62
4.8 Esquema elétrico para coleta de dados nos sensores de flexão.	63
4.9 Esquema elétrico para coleta de dados dos MEMS.	64
4.10 Matriz tridimensional para coleta da dinâmica dos gestos.	67
5.1 Dispositivos construídos: (a) Protótipo P_1 e (b) Protótipo P_2	72
5.2 Dispositivos construídos: (a) Protótipo P_3 e (b) Protótipo P_4	72
5.3 Bolsos de alocação dos MEMS e fios.	73
5.4 Diagrama esquemático das conexões dos componentes na construção do Protótipo P_3	74

5.5	Protótipo P_4 conectado ao computador.	75
5.6	Gestos: (a) número zero , (b) número 1 , (c) número 2 , (d) número 3 e (e) número 4	75
5.7	Gestos: (a) letra i e (b) letra j	77
5.8	Gestos: (a) letra a , (b) letra e , (c) letra i , (d) letra j , (e) letra x e (f) número 5	83
5.9	Relação dos valores obtidos nos sensores para gestos semelhantes: (a) gestos a e e , (b) gestos i e j e (c) gestos 5 e x	85
5.10	Sinais obtidos pela repetição do gesto a por 30 vezes.	86
5.11	Gestos: (a) telefone , (b) gato , (c) leão , (d) pipa e (e) amarelo	86
5.12	Fluxograma para coleta de gestos dinâmicos.	89

LISTA DE TABELAS

	<u>Pág.</u>
3.1 Codificação sequencial.	55
3.2 Codificação c -classes.	55
5.1 Sinais de saída do Protótipo P_1 para os gestos estáticos zero, 1, 2, 3 e 4	75
5.2 Sinais de saída do Protótipo P_3 para os gestos zero, 1, 2, 3 e 4	76
5.3 Média e desvio padrão dos sinais de saída do Protótipo P_3 para os gestos zero, 3 e 4	78
5.4 Sinais de saída do Protótipo P_3 para os gestos i e j	79
5.5 Matriz de configuração $Q(\mathbf{zero})$ adquirida pelo Protótipo P_1	80
5.6 Média de acertos da taxa de aprendizagem para 100 ensaios.	81
5.7 Média de acertos para variações do número de neurônios nas camadas intermediárias com 100 repetições.	82
5.8 Média de acertos para variações do número de neurônios nas camadas intermediárias com 500 repetições.	82
5.9 Média de acertos do Protótipo P_4 para os gestos a, e, i, j, x e 5	83
5.10 Média de acertos do Protótipo P_4 para as palavras.	84
5.11 Sinais coletados no tempo com o Protótipo P_4	87
5.12 Média e desvio padrão dos sinais obtidos no Protótipo P_4 para o gesto leão	88

LISTA DE SÍMBOLOS

α_m	– Termo de <i>momentum</i>
β	– Constante real relacionada a inclinação da função logística ou da função tangente hiberbólica
η	– Taxa de aprendizagem entre as camadas da MLP
τ	– Quantidade de amostras na camada de entrada
AD_0	– Porta que define o endereçamento I2C dos MEMS
A_s	– Vetor com os valores obtidos dos MEMS A_g
b	– Limiar de ativação do neurônio
C_1, C_2	– Capacitâncias entre a massa e os eletrodos fixos.
C_I	– Camadas intermediárias da MLP e nas camadas de saída
C_S	– Camadas de saída da MLP
D_{Ed}	– Entrada de dados do demultiplexador
D_{S_1} a D_{S_4}	– Sinais de saída do demultiplexador
E_1 a E_m	– Entradas de sinais no neurônio
E_c	– Entrada do <i>clock</i> para protocolo I2C
E_d	– Entrada de dados para protocolo I2C
E_{da1} a E_{da_K}	– Entradas de dados analógicos do microcontrolador
E_{dd1} a E_{dd_K}	– Entradas de dados digitais do microcontrolador
$e_{i,n}^{(p)}$	– Erro obtido entre as iterações da MLP
$E_{i,j}$	– Matriz de valores de entrada das camadas referente as conexões do i -ésimo neurônio da j -ésima camada
$g(\cdot)$	– Função de ativação do neurônio
I	– Sinal a ser normalizado
I_{max}	– Valor máximo de entrada para normalização de dados
I_{min}	– Valor mínimo de entrada para normalização de dados
k	– Número total de padrões a serem reconhecidos no conjunto de treinamento da MLP
K	– Número de sensores
K_x, K_y	– Molas de silício do giroscópio
lim^{sup}	– Limite superior que a função de ativação pode assumir
m_i	– Número de neurônios na camada intermediária
M_c	– Microcontrolador
M_e	– Matriz de entrada
$M_{S_{i,j}}$	– Matriz de valor desejado para saída
n	– Número de camadas
n_b	– Quantidade de <i>bits</i> do conversor analógico-digital
N_1 a N_4	– Neurônios da camada de saída da codificação de classes
O_{min}, O_{max}	– Limites mínimo e máximo para normalização de dados
O_n	– Sinal normalizado
p	– Contador de iterações da MLP
P_1 a P_4	– Protótipos desenvolvidos

Q_{cs}	– Quantidade de classes proveniente método codificação sequencial
$Q_{i,j}$	– Matriz de configurações
Q_{ns}	– Quantidade de neurônios da camada de saída
R	– Resistor responsável por gerar a tensão de saída V_{out} proporcional a tensão V_{in} .
R_c	– Resistência de <i>pull up</i> para protocolo I2C
R_p	– Resolução do conversor analógico-digital
R_{S_f}	– Resistência do sensor de flexão
S	– Saída do neurônio
SDA	– Porta de transmissão de dados da comunicação I2C
SCL	– Porta de <i>clock</i> da comunicação I2C
S_c	– Saída do <i>clock</i> para protocolo I2C
SC_1, SC_2	– Sinais de controle do demultiplexador
S_d	– Saída de dados para protocolo I2C
$S_{d,i,n}$	– Vetor de valor desejado para saída referente ao i -ésimo neurônio da camada de saída C_S , com $j = n$ na rede MLP
S_{f_1} a S_{f_5}	– Sensores de flexão
$S_{i,n}$	– Vetor de valor obtido pela saída atual referente ao i -ésimo neurônio da camada de saída C_S , com $j = n$ na rede MLP
$S_{i,j}$	– Matriz de valores de saídas das camadas referente as conexões do i -ésimo neurônio da j -ésima camada
S_{pp}	– Saída pós-processada pela MLP
S_s	– Vetor com os valores obtidos dos sensores de flexão S_f
t	– Intervalo de tempo
T	– Posição/número do gesto
u	– Potencial de ativação do neurônio
V_{CC}	– Tensão de alimentação do microcontrolador
V_g	– Vetor de cada gesto
V_{in}	– Tensão de alimentação da coleta do sinal de saída dos sensores de flexão
V_{out}	– Tensão de saída da coleta do sinal de saída dos sensores de flexão
V_{ref}	– Tensão de referência do microcontrolador
V_{S_1} a V_{S_4}	– Valores de saídas da codificação de classes
w	– Matriz de pesos da rede neural
w_1 a w_m	– Pesos sinápticos do neurônio
$w_{i,j}$	– Matriz de pesos referente as conexões do i -ésimo neurônio da j -ésima camada

CAPÍTULO 1

INTRODUÇÃO

As línguas de sinais são sistemas linguísticos específicos da comunicação utilizada pela comunidade surda. São constituídas por expressões visuo-espaciais com a finalidade de transmitir mensagens. A detecção automática e interpretação destes gestos é cada vez mais estudada e aplicada, cujo fato é justificado em função da inclusão social e comunicação assertiva entre surdos e ouvintes. O resultado da detecção depende das tecnologias utilizadas e o valor financeiro agregado a elas.

Pensava-se que a comunidade surda não poderia ser educada, devido a população acreditar que os surdos fossem incapazes (STOKOE, 1980; LACERDA, 1998; QUADROS; CRUZ, 2009). A partir do século XVI, consideravam o aprendizado através de procedimentos pedagógicos específicos, porém os trabalhos realizados pelos pedagogos eram tidos como segretos. No século XVIII, a proposta de educação defendia que os educadores deveriam aprender tais gestos para se comunicar com os surdos. Desta forma, eles aprendiam com os surdos e, através desta comunicação, ensinavam a língua falada e escrita (LACERDA, 1998).

Quadros e Cruz (2009) expõem que as consolidadas pesquisas linguísticas se iniciam em 1960, com Willian Stokoe, revelando que as línguas de sinais são línguas naturais que permitem exprimir qualquer ideia e se organizam como as línguas orais. Stokoe (1980) argumenta que o gesto pode ser composto por três elementos básicos: i) lugar no espaço; ii) configuração da mão e iii) movimento das mãos.

Após as afirmações de Stokoe, várias práticas de ensino para surdos foram criados. No Brasil, a técnica começou a ser investigada nas décadas de 1980 e foram realizadas traduções para o português de várias outras línguas de sinais (QUADROS; CRUZ, 2009; LACERDA, 1998). Semelhante as línguas orais, pode acontecer de cada país utilizar a mesma ou criar sua própria língua de sinais.

No século XXI, como continuação do trabalho de Stokoe, inicia-se o estudo linguístico considerando e identificando cinco parâmetros: i) localização, ii) formato da mão, iii) orientação, iv) movimentos e v) expressão facial (QUADROS; CRUZ, 2009; TAVARES et al., 2009). Apesar da divisão em cinco parâmetros ser amplamente adotada pelos estudiosos da área, não existe consenso sobre a quantidade de parâmetros utilizados (FERREIRA et al., 2011).

Para reconhecimento automático da língua de sinais existem duas abordagens clás-

sicas: a) abordagem visual e b) abordagem sensorial. Segundo [Kuroda et al. \(2004\)](#) e [Yang \(2010\)](#), as abordagens possuem vantagens e desvantagens quando comparadas entre si. Na abordagem sensorial, tem-se a necessidade do usuário acoplar dispositivos ao corpo para interagir com o sistema tradutor, promovendo elevada precisão na captação de movimentos. Em sua maioria, sistemas com abordagem sensorial utilizam luvas para acoplamento. Já na abordagem visual, a interação com a máquina é intuitiva, sem necessidade de vestir o equipamento, trazendo comodidade ao usuário.

Focados na abordagem sensorial, [Fang et al. \(2003\)](#) e [Zhang et al. \(2005\)](#) utilizam *cybergloves* e rastreadores de movimento como dispositivos para coleta de dados. *Cybergloves* são dispositivos sensoriais acoplados a mão, em formato de luva, com rastreadores acoplados ao pulso, em formato de pulseira. [Zhang et al. \(2005\)](#) apresentam algoritmo capaz de reconhecer situações nas quais a fonte geradora dos gestos está oculta ao observador. Os autores utilizam modelos Markovianos e adicionalmente trabalham com o algoritmo *Boosting Hidden Markov Mode* (HMM), que é capaz de aumentar a precisão do processo a partir de regra de decisão. Neste trabalho, [Zhang et al. \(2005\)](#) obtêm melhorias de até 3% no reconhecimento da língua chinesa de sinais, quando comparados com trabalhos que utilizam o HMM tradicional.

Outra proposta para a língua chinesa de sinais foi abordada por [Fang et al. \(2003\)](#), que demonstra a combinação de Mapas Auto-Organizáveis (*Self-Organizing Feature Maps* - SOFM) com HMM e apresenta aumento de precisão em 5%. Mapas Auto-Organizáveis são redes neurais capazes de mapear os dados de tal forma que mantenha relações de vizinhança, ou seja, dados com características parecidas ficam próximos no mapeamento.

[Bui e Nguyen \(2007\)](#) e [Li et al. \(2010\)](#) utilizam sensores de eletromiografia e acelerômetros para reconhecer gestos manuais, apresentando acertos acima de 93%. Os gestos segmentados podem ser detectados automaticamente de acordo com a amplitude de 4 canais. Com abordagem diferente, [Praveen et al. \(2014\)](#) utilizam pares de diodo emissor de luz com resistor dependente de luz (LED-LDR) para aquisição de dados do posicionamento dos dedos e reconhecimento de letras da língua de sinais, porém não apresenta resultados conclusivos. [Tubaiz et al. \(2015\)](#) utilizam sensores de flexão e acelerômetro para reconhecimento da língua de sinais vietnamita. O trabalho é dividido em três categorias, dependendo da posição e orientação das mãos. Apresenta resultados precisos para gestos que não rotacionam em relação ao eixo z .

Nos trabalhos de [Borghetti et al. \(2013\)](#), [Lei e Dashun \(2015\)](#), [Pathak et al. \(2015\)](#), [Das et al. \(2015\)](#) e [Tori et al. \(2006\)](#) destacam os sensores de flexão e fibra ótica acoplados em luvas para aquisição de dados referentes a flexão dos dedos. Tais luvas são desenvolvidas com rastreamento preciso e funcionam reduzindo a passagem de luz ou aumentando a resistência à passagem de corrente no circuito. Entretanto, desgastes na fiação e utilização contínua podem apresentar rupturas nos sensores, produzindo respostas indesejáveis.

Em geral, os dispositivos de reconhecimento da língua de sinais utilizam sensores de flexão, acelerômetros e sensores de eletromiografia (EMG). Dada as configurações dos dispositivos projetados e comerciais, as limitações em suas medições estão nos sensores e nas técnicas utilizadas para reconhecimento dos gestos. Outra limitação é a necessidade da substituição destes sensores, caso algum sensor se desgaste ou tenha quebras. Desta forma, o custo geral de produção é alto e tem-se a necessidade do desenvolvimento de dispositivo com menores restrições e custos. A literatura indica que diversos aspectos estão sendo tratados, tanto com a integração da abordagem sensorial e/ou baseada na visão, como com disponibilização de novos recursos tecnológicos ([KURODA et al., 2004](#); [YANG, 2010](#)).

Com o avanço da tecnologia, reduz-se os custos e as respostas de operação dos sensores são aperfeiçoados, em certos casos, acoplando-os no mesmo dispositivo. Vários trabalhos são desenvolvidos com o intuito de tratar os dados coletados de dispositivos comerciais para tradução da língua de sinais, através de tradução de padrões utilizando diversas técnicas. No entanto, a proposta deste estudo tem como foco a construção do dispositivo de tradução da língua de sinais, cujo um dos pares linguísticos é a Língua Brasileira de Sinais, português, justificando este trabalho. Logo, pode-se a partir do exposto, formular a hipótese básica: se os acelerômetros e giroscópios podem verificar localização, parte do formato da mão, orientação e movimento, e se esta combinação é capaz de capturar o padrão de cada movimento, pode-se então utilizá-los para tradução para a língua de sinais em substituição e/ou integração aos sensores comumente utilizados.

O objetivo principal deste trabalho é projetar, desenvolver e avaliar dispositivos para identificar configuração, orientação e movimento das mãos, traduzindo gestos da língua de sinais para a linguagem escrita. Ainda como objetivos têm-se: i) definir lei autêntica e componentes de aquisição, processamento e controle, ii) realizar a coleta e armazenamento das amostras de configuração, orientação e movimento das mãos, iii) definir parâmetros da rede neural, iv) treinar a rede neural artificial e v) reconhecer

gestos estáticos e dinâmicos da língua de sinais e converter em forma de texto.

A motivação para o trabalho surge da problemática encontrada pelo grupo de pesquisa do Instituto Politécnico do Porto (IPPorto/Portugal). O grupo ao desenvolver sistema Bidirecional de reconhecimento da língua de sinais, utiliza luvas comerciais de elevado custo, aproximadamente US\$5.000,00. A luva utilizada somente reconhece gestos estáticos e os sensores sofrem rupturas com a utilização contínua. Com esta problemática, o grupo do IPPorto realiza encontro com gestores e pesquisadores do Instituto Federal de Goiás, propondo-lhes o desafio de construção do hardware.

Por consequência, este trabalho é parte do Projeto Tradutor Bidirecional do MEC-SETEC que tem o objetivo de traduzir e interpretar a língua de sinais através de aparato que identifique os movimentos gestuais e comunique estes movimentos na forma da língua escrita para o computador. Os objetivos específicos do projeto destinam-se à: i) inclusão social, ii) integração da comunidade surda na Educação Profissional e Tecnológica, iii) aprimoramento do ensino da língua de sinais, iv) formação e capacitação de profissionais para a Educação Inclusiva da comunidade surda no Brasil e v) formação de turma do programa Professores para o Futuro, parceria entre Brasil e Portugal com certificação em Tecnologia Assistiva.

O trabalho foi dividido da seguinte forma: o Capítulo 2 descreve sobre a língua de sinais, o Capítulo 3 apresenta dispositivos de aquisição, processamento e comunicação, além de descrever sobre a rede neural artificial. O Capítulo 4 especifica a metodologia desenvolvida para a realização do trabalho, o Capítulo 5 detalha os resultados e discussões referentes ao desenvolvimento dos dispositivos e, por fim, o Capítulo 6 apresenta a conclusão. Neste trabalho entende-se como **gestos** os sinais realizados na construção da língua de sinais, como **sinais** os valores coletados/obtidos dos sensores e como **dados**, os valores dos sinais tratados e armazenados.

CAPÍTULO 2

LÍNGUA DE SINAIS

Este capítulo apresenta breve histórico da língua de sinais e a forma de comunicação dos surdos. Descreve sobre a datilologia e a construção linguística da língua de sinais, pontuando os aspectos fundamentais para seu entendimento, bem como suas contribuições para sociedade.

2.1 Comunicação dos surdos

A comunicação é fundamental para a sociedade, seja para interpessoalidade, troca de produtos, transmissão de valores e herança cultural (JAKOBSON, 2008). Na comunicação é utilizado mecanismos específicos de linguagem oral-auditiva e visuo-espaciais, para ouvintes e para surdos, respectivamente. Na comunicação, existem a necessidade de regras para que haja entendimento da mensagem a ser transmitida (SILVA, 2010). Estas regras podem ser expressas por acordos, normas, leis e outros.

2.1.1 Conceituação e legislação sobre a Língua Brasileira de Sinais

Comunicação é o campo do conhecimento que estuda os processos de troca de mensagens. É o intercâmbio da informação entre sujeitos ou objetos, podendo inclui temas técnicos, biológicos e sociais (MORAES; ARAUJO, 2010). Para que exista comunicação entre os indivíduos é necessária a transmissão da mensagem, que pode ser codificada em sons, indícios, gestos ou língua natural (MATTELART; MATTELART, 2011).

Os surdos são utilizadores da comunicação visuo-espacial como principal meio de conhecer o mundo em substituição à audição e à fala. A comunidade surda é constituída por indivíduos que utilizam da língua de sinais para se comunicarem. Pode ser ouvintes ou surdos, como especifica o Decreto nº 5.626 de 2005, que regulamenta a Lei nº 10.436 de 2002 e o art. 18 da Lei nº 10.098 de 2000. Este decreto dispõe sobre a Língua Brasileira de Sinais (Libras), que tem em seu teor (BRASIL, 2005):

(...) Art. 2º Para os fins deste Decreto, considera-se pessoa surda aquela que, por ter perda auditiva, compreende e interage com o mundo por meio de experiências visuais, manifestando sua cultura principalmente pelo uso da Língua Brasileira de Sinais - Libras.

Parágrafo único. Considera-se deficiência auditiva a perda bilateral, parcial ou total, de quarenta e um decibéis (dB) ou mais,

aferida por audiograma nas frequências de $500Hz$, $1kHz$, $2kHz$ e $3kHz$. (...)

O reconhecimento da Libras como língua oficial do Brasil ocorre no ano de 2002, por meio da Lei nº 10.436, que reconhece que a Libras é meio de comunicação e expressão e é constituída por natureza visual-motora e estrutura gramatical. A Lei nº 10.436 esclarece que devem ser instituídas formas para apoiar e propagar a Libras como meio de comunicação das comunidades surdas brasileiras e que as instituições de ensino devem garantir inclusão nos cursos de formação de educação especial (LODI, 2013).

2.1.2 Comunicação na comunidade surda

Segundo Costa (2014), Quadros (2009), Coelho et al. (2004), o deficiente auditivo era considerado nível sub-humano, incapazes de se comunicarem. No século XVI, com o trabalho realizado pelas famílias dos deficientes auditivos para que eles tivessem vida normal, provaram que estavam errados. A partir daí, a concepção sobre surdez tem sofrido transformações na medicina e na educação, influenciada pelos debates sobre inclusão social.

Anteriormente, o movimento de educação e inserção dos indivíduos surdos os denominavam de surdo-mudo. No século XVIII, com o avanço dos estudos, percebeu-se que os surdos eram capazes de falar, porém como não tinham referência de expressão da fala, não conseguiam emitir ruídos sonoros compatíveis aos ouvintes (NOVAES, 2010). Anterior a estes estudos, tem-se como mito que todos os surdos são capazes de realizar leitura labial e compreender o que está sendo dito. No entanto, para se fazer tal leitura, o indivíduo necessariamente deve ter domínio da língua oral, o que não é realidade para a maioria dos surdos (QUADROS; PERLIN, 2007; LACERDA, 1998). Tais fatos descrevem possíveis responsáveis por fazer a população acreditar que os surdos estão inseridos no mundo dos ouvintes, o que não é verdade para a maioria.

Durante o decorrer dos séculos, propôs-se abordagens de ensino distintas para educação das pessoa com surdez. Dentre elas, tem-se: i) oralismo, ii) comunicação total e iii) bilinguismo (LACERDA, 1998). Segundo Poker (2011), o oralismo visa a integração do surdo na comunidade dos ouvintes, para que desenvolva e aprenda a língua oral. Acredita-se que a surdez pode ser minimizada por meio da estimulação auditiva e, desta forma, integrar o surdo na comunidade dos ouvintes. Para Lacerda (1998), o oralismo determina que o indivíduo receba a linguagem oral através da leitura orofacial e amplificação sonora, enquanto se expressa através da fala. Nesta

concepção de aprendizagem, gestos, língua de sinais e alfabeto são expressamente proibidos.

A comunicação total é definida por integrar a aprendizagem da língua oral com recursos visuo-espaciais. Desta forma, utiliza aspectos cognitivos, emocionais e sociais para facilitar a comunicação. Nesta abordagem, os educadores começam a se preocupar com nova forma de linguagem (POKER, 2011). Por fim, o bilinguismo admite que o surdo possua língua própria, agregando no desenvolvimento e relação entre o surdo e o mundo. Para Ferreira-Brito (2010), o aprendizado da língua de sinais deve ser oferecido o mais precocemente possível a criança, para que o mesmo possa fortalecer o pensamento e estimular o desenvolvimento cognitivo e social.

Para Quadros e Karnopp (2009), a língua de sinais é dada pela percepção dos indivíduos, de se comunicarem de forma natural, construindo formas comunicativas e estruturadas não apenas no uso de gesticulação através das mãos, mas também utilizando as expressões faciais. Os autores especificam que tais línguas naturais refletem na capacidade psicobiológica humana e que passam de geração em geração. Segala et al. (2010) descrevem que mesmo sabendo que a comunicação dos surdos surge de forma natural, deve-se respeitar a construção linguística da língua de sinais para criação de novos gestos e novas alterações. Formalizando a construção e a sistematização da língua de sinais, toda a comunidade pode se comunicar de maneira assertiva (MASUTTI; SANTOS, 2008).

No século XVI, o monge espanhol Pedro Ponce de León registra o primeiro alfabeto manual, mas somente a partir de 1880 começam a aparecer pequenos folhetos com ilustrações de gestos (RAMOS, 2005). No Brasil, a Língua Brasileira de Sinais, conhecida por Libras, sofreu influência da França, por iniciativa do fundador do Instituto Nacional de Educação de Surdos (INES), Ernest Huet, que além de fundador e professor, foi diretor do Instituto de Surdos francês (SOUSA, 2012).

2.2 Mitos da língua de sinais

A língua de sinais é normalmente descrita e analisada de forma equivocada, necessitando desmistificar certas ideias ou mitos. Quadros e Cruz (2009) e Forster (2013) descrevem seis mitos referentes a língua de sinais e demonstram a necessidade do entendimento desta cultura.

2.2.1 Primeiro mito

A língua de sinais seria a mistura de pantomima e gesticulação concreta, incapaz de expressar conceitos abstratos. Ao contrário do que vários julgam, a língua de sinais não pode ser considerada como mímica. Mesmo que vários gestos possam ser realizados de forma a imitar o objeto a ser representado, isto não é regra. Os sinais são constituídos de propriedades específicas e podem expressar pensamentos abstratos e é possível discutir economia, política, matemática ou mesmo desempenho.

2.2.2 Segundo mito

Há única e universal língua de sinais usada por todas as pessoas surdas no mundo. E isto é comum de imaginar, porém, na verdade, existem variações para cada país e inclusive, dentro da mesma língua de sinais. Da mesma forma que na língua oral, existem sotaques e variações linguísticas.

2.2.3 Terceiro mito

Há falha na organização gramatical da língua de sinais, sendo pidginização (língua resultante do contato entre outras línguas) sem estrutura própria, subordinado e inferior às línguas orais. Outro aspecto que causa equívoco é admitir que as línguas de sinais são subordinadas às línguas orais. Da mesma forma em que a língua portuguesa oral de Portugal e do Brasil são diferentes, as línguas de sinais também podem diferir. Outro ponto relevante é que as línguas de sinais não são línguas orais soletradas com as mãos, o alfabeto manual serve para auxiliar ouvintes e surdos quando não se sabe determinado gesto. Seria desgastante escrever sentenças com a soletração.

2.2.4 Quarto mito

A língua de sinais seria sistema de comunicação superficial, com conteúdo restrito, sendo estética, expressiva e linguisticamente inferior ao sistema de comunicação oral. A língua de sinais é autônoma e reconhecida por sua construção linguística, que é completa e possui gramática, semântica, pragmática dentre outros aspectos relevantes para comunicação. Erroneamente, julgam que a língua de sinais não tem elementos de ligação, porém, é modalidade visuo-espacial e agrega todos os gestos por meio de expressões faciais e corporais.

2.2.5 Quinto mito

As línguas de sinais derivam da comunicação gestual espontânea dos ouvintes. A língua de sinais possui todos os elementos que a tornam língua. Da mesma forma em que é necessário dedicar tempo para aprender outra língua oral, deve-se empenhar no aprendizado da língua de sinais. É discutido se o aprendizado da língua de sinais poderia afetar os estudos referentes ao desenvolvimento linguístico da língua oral. Porém, deve-se questionar o puro aprendizado do surdo da oralização, pois o surdo pode ter maior dificuldade para conseguir falar e compreender línguas orais. Além disto, nem sempre o surdo poderá aprender e entender a leitura labial. Ele até pode ler nos lábios as palavras, porém o significado destas palavras nunca foi lhe explicado, então ele não entenderá a mensagem.

2.2.6 Sexto mito

As línguas de sinais, por serem organizadas espacialmente, estariam representadas no hemisfério direito do cérebro, uma vez que este hemisfério é responsável pelo processamento de informação espacial, enquanto que o esquerdo, pela linguagem. [MENEZES et al. \(2009\)](#) explica que independente da modalidade das línguas, a língua de sinais é processada no hemisfério esquerdo, assim como qualquer outra língua. Como exemplificado por [HICKOK et al. \(2004\)](#), se por ventura a pessoa que se comunica por gestos possuir lesão no hemisfério direito, não teria capacidade para criar ou copiar desenhos reconhecíveis ou perceber objetos na parte esquerda do seu campo visual, pois isto, é negligência hemiespacial. Porém, pode-se comunicar de modo eficiente na língua de sinais. Como qualquer língua oral, a língua de sinais é constituída por componentes linguísticos fundamentais para comunicação coesa e organizada.

2.3 Construção linguística da língua de sinais

Como toda língua, a Língua Brasileira de Sinais é composta por componentes de construção linguística, tais como: i) fonética, ii) morfologia, iii) sintaxe, iv) semântica, v) pragmática e iv) fonologia ([QUADROS; CRUZ, 2009](#)).

[STROBEL e FERNANDES \(1998\)](#) descrevem a fonética como a área que estuda o som e como ele é produzido. Para a língua de sinais, a preocupação da fonética é retratada pelas características físicas e de articulação da fonação. [Almeida \(2014\)](#) e [Sousa \(2012\)](#) descrevem como a morfologia combina elementos para a formação das palavras, compondo número, gênero e pessoa. A sintaxe trata da estrutura das frases,

suas funções e todas as partes do discurso falado. A semântica estuda o significado geral da palavra e relaciona-se a natureza, função e usos dos específicos significados das palavras. A pragmática estuda o contexto pelo qual está tratado a sentença e os princípios de comunicação.

Segundo Sousa (2012), a fonologia na língua de sinais estuda os diferentes tipos de fônicas intencionais, que se combinam para formar palavras e frases. Já para Quadros e Cruz (2009), a fonologia é o ramo que identifica a estrutura e organização das expressões, determinando padrões de combinação entre elas. De forma geral, é a fonologia que reconhece os parâmetros que compõem a estrutura da Libras.

Stokoe (1980) descreve que os principais parâmetros fonológicos são ponto de articulação, movimento e configuração das mãos. Porém, após estudos, adicionou-se a orientação da mão e expressões faciais (QUADROS; CRUZ, 2009; TAVARES et al., 2009). Assim, tem-se que os parâmetros fonológicos da língua de sinais são: i) ponto de articulação, ii) configuração da mão, iii) movimento, iv) orientação e v) expressões.

O ponto de articulação é a área ou espaço onde incide a mão, em que os gestos são articulados. Destaca-se quatro áreas: cabeça, mão, tronco e espaço neutro. Espaço neutro é quando o gesto pode ser realizado em qualquer espaço em frente ao corpo (RODRIGUES; VALENTE, 2010). A configuração da mão trata-se do formato em que as mãos estão no gesto. No decorrer da execução do gesto, poderá haver variação do alinhamento do punho e da configuração de mão. O movimento é outro parâmetro e se refere ao trajeto das mãos durante o gesto. A Figura 2.1, criada a partir da fonte para uso em editores de texto para Libras, ilustra 36 de várias configurações de mãos existentes (datilologia ou alfabeto manual). Para Quadros e Cruz (2009) e Tavares et al. (2009), os movimentos podem ser retilíneos, helicoidais, circulares, semicirculares, sinuosos e angulares. Além disto, a mesma configuração de mãos com movimentos distintos expressam assuntos distintos.

O parâmetro de orientação designa a direção em que a mão produz o movimento do gesto. Entre eles, tem-se cima, baixo, direita e esquerda (QUADROS; KARNOPP, 2009). A expressão é fundamental para a utilização da língua de sinais, pode ser facial ou corporal. Elas diferenciam o teor da mensagem que está sendo transmitida (QUADROS; CRUZ, 2009; TAVARES et al., 2009).

A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	0	1	2	3
4	5	6	7	8	9

Figura 2.1 - Alfabeto manual

2.4 Datilologia

A datilologia é empréstimo linguístico para a língua de sinais, capaz de soletrar palavras da língua oral para o alfabeto manual. A datilologia também é capaz de ilustrar palavras sem gestos específicos, nomes próprios que ainda não tenham gestos, nomes de lugares, gestos novos, entre outros. De forma geral, a datilologia expressa letras e números do alfabeto utilizada pela língua oral (RAMOS, 2005).

A datilologia apresenta três parâmetros fundamentais: i) movimento, ii) configuração e iii) orientação da mão. A palavra descrita por meio da datilologia é expressa de forma linear e cada letra é representada individualmente. É composta por 26 letras e 10 números do alfabeto latino (FERNANDES; ROMEIRO, 2017).

2.5 A língua de sinais e datilologia pelo mundo

A língua de sinais é necessária em todo o mundo, porém como na língua oral, vários países têm sua própria língua de sinais, dificultando a interatividade. A forma em que as línguas de sinais são criadas refere-se ao contexto histórico em que foram consolidadas e a forma em que a comunidade surda assimilava objetos e, assim, gestos. Com os anos, passam a ter linguagem bem definida (QUADROS; CRUZ, 2009; TAVARES et al., 2009).

Phi et al. (2015) apresentam o alfabeto vietnamita como sistema moderno para a língua vietnamita. O alfabeto manual vietnamita inclui 29 letras e usa como referência o alfabeto latino, com base nos alfabetos de línguas românicas. Línguas românicas ou neolatinas são as línguas modernas que evoluíram do latim vulgar (latim falado). O trabalho de Das et al. (2015) especifica que o alfabeto indiano da língua de sinais (*Indian Sign Language* - ISL) também têm 29 letras.

A língua de sinais árabe (*Arabic Sign Language* - ArSL), descrita em Ahmed et al. (2016), foi reconhecida e documentada para ser padronizada e usada em todos os países árabes. Sarawate et al. (2015) descrevem que no Reino Unido e nos Estados Unidos da América utilizam o inglês como língua falada e em ambos países a diferença na língua está somente no sotaque. Porém, a língua de sinais americana (*American Sign Language* - ASL) foi criada por professores franceses, desta forma é similar a língua de sinais francesa (*French Sign Language* - FSL). No entanto, a língua de sinais britânica (*British Sign Language* - BSL) é similar a língua de sinais turca (*Turkish Sign Language* - TSL). Ambas com 26 letras e algumas letras bastante semelhantes.

As letras, quando iguais ou semelhantes, produzem problemas de reconhecimento. Nas línguas de sinais vietnamita e inglesa são admitidos gestos semelhantes, por exemplo, no alfabeto ASL, as letras **A**, **M**, **N**, **S** e **T** são gesticuladas com o punho fechado. O formato da mão para estas cinco letras parecem ser as mesmas (BUI; NGUYEN, 2007). Na Libras, as letras **A**, **E**, **S** e o número **8** têm formatos semelhantes. Esta problemática dificulta o acesso aos surdos se comunicarem com pessoas fora da sua comunidade, produzindo a necessidade de intérprete para estabelecer a comunicação entre as pessoas da comunidade surda, assim como na língua falada (QUADROS; CRUZ, 2009).

2.6 Considerações

Seja no âmbito educacional ou social, o uso da língua de sinais se torna primordial para a inserção dos surdos na sociedade. Deste modo, este capítulo descreve sobre a língua de sinais, a construção e suas particularidades. Além disto, este capítulo exemplifica de forma abrangente o alfabeto manual de alguns países, interligando sua construção linguística as línguas de sinais. No próximo capítulo serão apresentados os dispositivos de aquisição e processamento de dados relevantes para a construção da base de dados.

CAPÍTULO 3

SISTEMA DE MANIPULAÇÃO DE DADOS E RECONHECIMENTO DE PADRÃO

Neste capítulo são apresentados conceitos referentes à aquisição e processamento de dados, dispositivos transdutores de sinais e as formas de comunicação e programas necessários para realização da comunicação entre os transdutores. Ainda são apresentados conceitos referentes a rede neural artificial, com foco no Perceptron múltiplas camadas.

3.1 Processamento de dados

Para implementar qualquer método de reconhecimento de padrão são necessários: i) os sensores para obtenção dos dados do sistema a ser reconhecido, fazendo com que sejam apresentados apenas dados relevantes para o reconhecimento, ii) o mecanismo de extração de características, efetuando a análise dos dados de saída do sistema e entrada na rotina computacional, de forma a extrair e derivar informações úteis para o processo de reconhecimento e iii) a identificação ou classificação destes dados, cujos resultados serão categorizados conforme seus padrões (CUNHA et al., 2007). A Figura 3.1 ilustra o diagrama simplificado do processo de reconhecimento de padrão.




Figura 3.1 - Diagrama simplificado do processo de reconhecimento de padrão.

A aquisição dos dados (amostras) de saída do sistema ocorre a partir dos valores coletados dos sensores. Esta amostra ou base de dados é chamada de *template*. A

amostra coletada é analisada com o objetivo de averiguar sua qualidade e após a análise a amostra é armazenada. Após a aquisição dos dados de saída do sistema, parte-se para o processamento dos dados. Os dados de saída do sistema agora serão os dados de entrada da rotina computacional (LIBONATI; OLIVEIRA, 2002). A transformação dos dados de entrada da rotina computacional em determinado conjunto de características, é chamado de extração de características. Após as escolhas das características extraídas, espera-se que o conjunto de características final represente parte relevante da informação. Desta forma, utiliza-se o conjunto de características, ao invés de usar os dados de saída do sistema, reduzindo o esforço computacional (CHEVALLIER, 2001).

A extração de característica envolve a simplificação do conjunto de dados de entrada da rotina computacional, requeridos para descrever elevado conjunto de dados com precisão. Analisar elevado conjunto de dados com variações numéricas requer quantidade de memória e esforço de processamento elevado (CHEVALLIER, 2001). O conjunto de semelhanças do conjunto de características é denominado padrão. A união dos conceitos característica e padrão tem a finalidade de analisar conjuntos de dados e organizá-los de acordo com padrões/características, do qual a descrição de determinada situação recorrente e sua solução podem ser reutilizadas diversas vezes em diversas situações (CHEVALLIER, 2001).

Por fim, tem-se a identificação ou classificação de objetos de estudo dentro de número de categorias ou classes. Estes objetos de estudo variam de acordo com cada aplicação, podendo ser imagens, sinais em forma de ondas ou qualquer tipo de medida que necessite ser classificada (CUNHA et al., 2007). A identificação ou classificação é geralmente baseada na disponibilidade do conjunto de padrões classificados, chamado de conjunto de treinamento. Para funcionar corretamente, estes classificadores não podem ser generalizados, pois sua classificação será vaga, mas não podem ser específicos, pois deixarão de reconhecer elementos relevantes. Nesta etapa, novos dados são coletados utilizando o dispositivo/sensor, as características são extraídas a partir destes novos dados e comparadas com o *template*, reconhecendo ou não o padrão (LIBONATI; OLIVEIRA, 2002).

Para Cunha et al. (2007), a aquisição de dados é o processo pelo qual fenômenos físicos são transformados em sinais proporcionais e convertidos em formatos digitais compatíveis para posterior visualização, armazenamento, processamento e análise. O sistema de aquisição e processamento de dados é composto por fenômeno físico, captado por sensores e transdutores, cabos de ligação, equipamento de aquisição e

software de aquisição e processamento (CHEVALLIER, 2001).

3.2 Aquisição de dados, instrumentação e medidas

Instrumentação é a ciência que aplica técnicas para adequação de dispositivos de medição, transmissão, indicação, registro e controle de variáveis físicas em equipamentos nos processos industriais (BALBINOT; BRUSAMARELLO, 2000). A instrumentação é responsável por fazer medições e verificar características de cada tipo de medição e grandeza física (BALBINOT; BRUSAMARELLO, 2000). Estes sistemas de medição são chamados sensores ou transdutores. Eles são capazes de medir grandezas físicas, ou seja, obter a grandeza do ambiente e transformá-las em energia compatível aos sistemas microprocessados.

Webster e Eren (2014) e Balbinot e Brusamarello (2000) informam que após as medições, faz-se necessário recolher informação sobre os sistemas para o processo de tomada de decisões e para isto, utilizam-se condicionadores de sinais e processadores. Os condicionadores de sinais são responsáveis por converter a saída dos sensores ou transdutores em sinais elétricos compatíveis ao dispositivo de controle e o processador é o responsável por manipular as informações coletadas.

Existem vários tipos de sensores, cada um com sua especificidade. Os sensores têm suas características modificadas por fenômenos ocorridos em seus corpos, de forma a gerar variações nos agentes físicos tais como platina, resistência elétrica, força eletromotriz, dilatação térmica entre outros (BALBINOT; BRUSAMARELLO, 2000). A partir destas variações, é possível medir variáveis como pressão, vazão, nível, movimento, velocidade, temperatura entre outras.

3.2.1 Sensores de flexão

Os sensores de flexão são construídos com materiais plásticos flexíveis produzidos com filme resistivo de carbono que são partículas condutoras, ao se deformar proporcionam resistência a passagem de corrente elétrica (NASCIMENTO et al., 2017). Convertem a alteração da flexão (ou curvatura) em resistência característica equivalente de forma linear. Assim, quanto maior a flexão, maior a resistência. A Figura 3.2, adaptada de Barclay et al. (2011), ilustra o sensor de flexão. A maleabilidade, compactação, robustez, eficácia de medição e baixo consumo de energia tornam os sensores de flexão úteis para múltiplas aplicações em diversos campos (SAGGIO et al., 2015).




Figura 3.2 - Sensor de flexão.

3.2.2 Acelerômetro e giroscópio

Os acelerômetros são sensores/transdutores que medem as acelerações aplicadas nos eixos x , y e z do dispositivo. Com o acelerômetro é possível obter informações sobre grandezas físicas da cinemática e da dinâmica, como velocidade, aceleração, força ou mesmo o tempo de resposta durante dado evento (KNIGHT et al., 2007).

O acelerômetro tem sua ideia baseada no mecanismo mais utilizado para medição da aceleração, o sistema massa-mola, a combinação da lei de Newton de aceleração de massa e a lei de Hooke de ação de mola. De modo que quando o dispositivo acelera, a inércia faz com que a massa resista (BEEBY, 2004). A frequência natural, vibração e amortecimento também são avaliados, sendo assim, o sensor verifica as oscilações e o tempo de resposta do sistema massa-mola em alguma frequência natural característica (OKADA, 2012).

Mayagoitia et al. (2002) relatam que a sensibilidade é um dos parâmetros mais importantes para os acelerômetros, pois descreve a conversão entre vibração e tensão em frequência de referência, como $160Hz$. A sensibilidade é determinada pelo fabricante. Além disto, antes de cada aquisição de aceleração é necessária a calibração inicial, para obter parâmetros iniciais do dispositivo.

Existem tipos diferentes de acelerômetro, com um eixo ou mais de um eixo. Com um eixo, é utilizado para verificar vibração mecânica, enquanto que com mais eixos são capazes de realizar a medição da translação e da rotação dos corpos rígidos (SILVA, 2013).

A Figura 3.3, adaptada de Maenaka (2008), ilustra o acelerômetro de dois eixos, onde internamente, a massa é sustentada por molas de silício e o deslocamento delas

é motivado pela aceleração do corpo, justificado pelo princípio da inércia e medido pela mudança das capacitâncias C_1 e C_2 entre a massa e os eletrodos fixos.




Figura 3.3 - Estrutura interna do acelerômetro.

Para adquirir informações completas de deslocamento do corpo no espaço, faz-se necessária a informação produzida por outro sensor, o giroscópio. Os giroscópios medem a velocidade de rotação em torno do seu centro de rotação, assim o deslocamento angular pode ser medido pela integração deste sinal (FORHAN; SENNA, 2010; LIMA et al., 2013). A velocidade angular é obtida medindo a força de inércia de Coriolis sobre a massa vibrante. Em medições com giroscópios, existem erros do tipo sistemático, que ocorrem normalmente devido aos defeitos de fabricação e interferências externas. Outro erro é do tipo aleatório, que incluem os ruídos, sinais normalmente aditivos e de alta frequência. Para solucionar tais erros é recomendável adicionar filtros digitais (SOUZA, 2015). Assim como no acelerômetro, é necessária a calibração inicial.

A Figura 3.4, adaptada de Maenaka (2008), ilustra o giroscópio de um eixo com dois módulos de molas de silício, K_x e K_y . O K_x suporta a estrutura externa, enquanto K_y permite a vibração na direção do eixo y . Segundo Maenaka (2008), a força inercial Coriolis, referente ao eixo z , resulta do movimento na direção do eixo x . Este movimento da parte externa causa variação da capacitância entre eletrodos fixos e móveis conectados na estrutura.




Figura 3.4 - Estrutura interna do giroscópio.

Existem dispositivos que agrupam os dois ou mais sensores em um só, os quais podem ser classificados como Sistemas Micro-eletromecânico (*Microelectromechanical systems* - MEMS), que são mais compactos e menos onerosos em comparação aos sensores utilizados separadamente. Um exemplo é o MEMS que acompla acelerômetro e giroscópio em mesmo invólucro (*chip*). A Figura 3.5, adaptada de [Invensense \(2016\)](#), ilustra os três tipos de unidades inerciais responsáveis por acoplar os dois dispositivos, acelerômetro e giroscópio.




Figura 3.5 - Unidades inerciais.

[Farrell \(2008\)](#), [Barshan e Durrant-Whyte \(1995\)](#), [Woodman \(2007\)](#) descrevem que a unidade de referência inercial (*Inertial Reference Unit* - IRU) é capaz de verificar a velocidade angular nos três eixos ortogonais, a unidade de medida inercial (*Inertial Measurement Unit* - IMU) refere-se a habilidade de obter respostas de aceleração

através do uso de acelerômetros e, por fim, o sistema de navegação inercial (*Inertial Navigation System* - INS) é o sistema embarcado capaz de realizar a leitura dos sensores inerciais através de algoritmos que verificam dados de cada um dos sensores e identificam padrão de movimento. Desta forma, é possível fazer a aquisição de dados de velocidade e posicionamento. Alguns exemplos de aplicação dos acelerômetros e giroscópios são orientação de tela, *air bag*, realidade virtual e jogos, robótica, posicionamento de dispositivos, compensação de inclinação entre outros.

Os MEMS possuem o recurso processamento digital de movimento (*Digital Motion Processor* - DMP), que é responsável por realizar o processamento dos algoritmos de detecção dos movimentos nos seis eixos dos sensores (x , y e z dos acelerômetro e giroscópio). Este recurso auxilia e agiliza nos cálculos necessários para verificar posicionamento, rotação, aceleração, tempo de giros e outros (FARRELL, 2008).

3.2.3 Comunicação entre os dispositivos

Uma das formas de realizar a comunicação entre os dispositivos e o computador é utilizando os microcontroladores, que são dispositivos de circuitos integrados compostos por unidade lógica e aritmética, unidade de controle, memórias, periféricos de entrada e de saída, temporizadores, porta de comunicação serial entre outros. São componentes programáveis que permite aplicação no controle de diversos processos (DESHMUKH, 2005). A Figura 3.6 ilustra o microcontrolador, onde V_{CC} é a tensão de alimentação, SDA é a porta de transmissão de dados, SCL é a porta de *clock*, E_{da1} a E_{da_K} são as entradas de dados analógicos e E_{dd1} a E_{dd_K} são as entradas de dados digitais.




Figura 3.6 - Ilustração do microcontrolador.

Quando os microcontroladores são conectados aos hardwares, podem gerenciar e otimizar funções específicas relacionadas a estes periféricos. Para que todos os componentes conectados ao microcontrolador se comuniquem, realizando a aquisição, processamento e trabalhando em conjunto, deve existir comunicação entre os mesmos. Existem vários protocolos capazes de realizar a comunicação entre sensores e microcontrolador (GALLO et al., 2003), porém, na maioria dos MEMS utilizam-se o protocolo circuito inter-integrado (*Inter-Integrated Circuit* - I2C), que oferece comunicação, baixo custo computacional e rápida configuração de escravos na rede de comunicação.

A interface I2C é composta por dois fios bidirecionais, o *serial data line* (SDA) e o *serial clock line* (SCL). Cada dispositivo conectado ao barramento tem endereço único e pode agir como mestre ou escravo. O mestre é aquele dispositivo que coordena as operações do sistema, inicia a comunicação e solicita dados dos escravos. Os escravos recebem a requisição do mestre e retornam os dados solicitados, ficando limitado a comunicar-se apenas com o mestre.

Para transferir os dados, todos os outros dispositivos ligados ao barramento são considerados escravos e o dispositivo mestre é aquele que inicia a transmissão de dados no barramento e gera os sinais SCL para a sincronia da transmissão (ARCE et al., 2007; VERONESI, 2006; MONTEIRO et al., 2014). A Figura 3.7 ilustra o esquemático padrão de ligação do protocolo I2C, com entrada de dados E_d , entrada do *clock* E_c , saída de dados S_d , saída do *clock* S_c e as duas resistências R_c que ajustam alimentação no barramento com a tensão V_{CC} fornecida.

Para auxiliar no tempo de aquisição e processamento de dados, pode-se utilizar demultiplexadores adicionalmente ao protocolo I2C. O demultiplexador funciona como selecionador, onde os bits de controle selecionam cada porta/sensor e controla continuamente o fluxo para saídas de dados (ORDONEZ, 2003).

A Figura 3.8 ilustra o demultiplexador com dois sinais de controle S_{C_1} e S_{C_2} mais quatro sinais de saída D_{S_1} a D_{S_4} e a entrada D_{E_d} , que recebe as informações que serão transmitidas pelas portas selecionadas. Quando os *bits* de controle são modificados via microcontrolador, uma das saídas fica em estado baixo e todas as outras em estado alto (WIRTH, 2012). Desta forma, quando o multiplexador for ativado fará com que cada sensor seja ativado individualmente, após tempo determinado por programação. O demultiplexador é sistema de transmissão de dados síncrona, onde emissor e receptor são sincronizados pelo mesmo *clock*.




Figura 3.7 - Esquema elétrico para conexão e utilização do protocolo I2C.




Figura 3.8 - Sistema demultiplexador.

3.3 Perceptron Múltiplas Camadas

As redes neurais artificiais (RNA) são baseadas no modelo conexionista dos sistemas nervosos biológicos, os quais, por meio da interconexão massiva de neurônios, permitem o desenvolvimento de atividades aos seres com sistema nervoso (HAYKIN et al., 2009; SCHALKOFF, 1997). Pode-se caracterizar RNA como modelos computacionais

baseados em processamento distribuído paralelo com propriedades particulares como habilidade para aprender, generalizar, classificar e organizar dados. Tem seu modelo desenvolvido, genericamente, por algumas características principais: i) estado de ativação e função de saída para cada unidade da rede; ii) padrão de conectividade, o qual é definido por matriz de pesos w ; iii) regra para propagação dos estados de ativação (função de ativação) e iv) regra de aprendizado, para modificação do padrão de conectividade da rede usando a informação fornecida pelo ambiente externo, ou seja, para modificar a matriz de pesos (SILVA et al., 2010).

3.3.1 Neurônio Artificial

O sistema nervoso central humano é formado por conjunto de neurônios biológicos, cada conjunto responsável por determinada função. Da mesma forma, a rede neural artificial é formada por módulos que simulam o funcionamento dos neurônios, que recebem e transmitem informações referentes aos padrões em estudo (KHASHEI; BIJARI, 2010; ANDRADE, 2011).

A Figura 3.9 ilustra a configuração de único neurônio artificial, onde m é o número de neurônios/sinais de entrada, representados por E_1 a E_m , com pesos sinápticos w_1 a w_m e saída S . Para processamento da informação dos neurônios, é fundamental a relação entre três componentes: i) peso sináptico, ii) somador ou combinador linear e iii) função de ativação.




Figura 3.9 - Neurônio artificial.

Os sinais de entrada E são advindos do meio externo, representando as variáveis específicas da aplicação. Os pesos sinápticos w são caracterizados pela força da co-

nexão entre os neurônios da rede. O somador ou combinador linear, é a função que reúne todos os sinais de entrada com seus respectivos pesos sinápticos, produzindo o potencial de ativação u , que realiza a soma das entradas do neurônio multiplicadas pelos pesos sinápticos correspondentes. Complementarmente, tem-se o limiar de ativação ou *bias*, dado por b , que tem aplicação externa com capacidade de aumentar ou diminuir a entrada da função de ativação, a fim de otimizar o resultado da RNA. A saída S é o valor final obtido pelo neurônio, a partir de determinado grupo de sinais de entrada (NORGAARD et al., 2000).

3.3.2 Função de ativação

Na Figura 3.9, $g(\cdot)$ é a função de ativação, que tem como objetivo limitar a saída do neurônio. Nas Figura 3.10(a) a Figura 3.10(e) são ilustradas algumas funções de ativação usuais, que podem ser: i) função degrau, Figura 3.10(a); ii) função degrau bipolar, Figura 3.10(b); iii) função linear, Figura 3.10(c); iv) função logística ou sigmoidal, Figura 3.10(d) e v) função tangente hiperbólica, Figura 3.10(e) (ANDRADE, 2011; SILVA et al., 2010). A função de ativação degrau dada por (3.1) assume valor unitário positivo quando o potencial de ativação for maior ou igual a *zero*.




Figura 3.10 - Funções de ativação: (a) degrau (3.1), (b) degrau bipolar (3.2), (c) linear (3.3), (d) logística (3.4) e (e) tangente hiperbólica (3.5).

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (3.1)$$

A função de ativação degrau bipolar dada por (3.2) atribui valor unitário positivo quando o potencial de ativação for maior que *zero*, valor *zero* quando o potencial de ativação for *zero* e valores unitários negativos quando o potencial de ativação for menor que *zero*.

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (3.2)$$

A função de ativação linear ou rampa simétrica, dada por (3.3), assume valores iguais aos do potencial de ativação, definidos no intervalo $(-a, a)$ e restringe aos valores $(-a, a)$ quando maior ou menor que os limites.

$$g(u) = \begin{cases} a, & \text{se } u > a \\ u, & \text{se } -a \leq u \leq a \\ -a, & \text{se } u < -a \end{cases} \quad (3.3)$$

A função de ativação sigmoideal ou logística, dado por (3.4), assume valores no intervalo $(0, 1)$.

$$g(u) = \frac{1}{1 + e^{-\beta \cdot u}} \quad (3.4)$$

onde β é a constante real relacionada a inclinação da função logística.

A função de ativação tangente hiperbólica resulta em valores no intervalo $(-1, 1)$ e é dada por:

$$g(u) = \frac{1 - e^{-\beta \cdot u}}{1 + e^{-\beta \cdot u}} \quad (3.5)$$

onde β é a constante real relacionada a inclinação da função tangente hiperbólica.

3.3.3 Modelo do Perceptron múltiplas camadas

O modelo mais simples de RNA é o Perceptron, que é construído a partir do modelo do neurônio artificial e possui apenas uma camada. Este modelo foi criado por [Rosenblatt \(1958\)](#) e o modelo matemático de saída do neurônio artificial é dado por:

$$S_{i,n} = g(u) = g\left(\sum_{i=1}^m w_i \cdot E_i + b\right) \quad (3.6)$$

onde $i = 1, 2, \dots, m$ representa o i -ésimo neurônio de determinada camada.

O Perceptron admite valores ou parâmetros específicos para cada componente que o compõe. Os sinais de entrada devem ser reais ou binários e os pesos sinápticos e limiar de ativação são reais e inicializados aleatoriamente ([HAYKIN et al., 2009](#); [SILVA et al., 2010](#)).

A partir do modelo Perceptron de uma camada, pode-se implementar a configuração Perceptron múltiplas camadas (*Multi-Layer Perceptron* - MLP). A Figura 3.11 ilustra a topologia da MLP na presença de várias camadas intermediárias de neurônios ([SILVA et al., 2010](#); [HAYKIN et al., 2009](#)).




Figura 3.11 - Perceptron múltiplas camadas

A rede MLP ilustrada na Figura 3.11 apresenta número finito de neurônios nas

camadas intermediárias C_I e nas camadas de saída C_S . O número de camadas intermediárias m_i e seus respectivos neurônios dependem da complexidade do problema a ser solucionado, dos valores escolhidos para a camada de entrada e dos parâmetros atribuídos inicialmente (CUNHA et al., 2007; SCHALKOFF, 1997). Como ilustrado na Figura 3.11, a quantidade dos sinais de saída é igual ao número de neurônios da camada de saída S_{m_s} , quanto mais complexo o problema de reconhecimento, maior a quantidade de sinais e neurônios na camada de saída.

A definição da quantidade de camadas intermediárias da rede e o número de neurônios em cada camada são de extrema importância para seu desempenho, principalmente no que se refere à sua capacidade de generalização. Segundo Cybenko et al. (1988), a utilização de duas ou mais camadas intermediárias somente é necessária quando o problema a ser resolvido apresenta descontinuidades. Ao utilizar elevado número de camadas, geram-se problemas de convergência da rede, já que as camadas intermediárias trabalham com estimativas de erro. Nem sempre é possível conhecer a topologia necessária para cada aplicação (SCHALKOFF, 1997; HAYKIN et al., 2009; ANDRADE, 2011; BEBIS; GEORGIPOULOS, 1994).

O algoritmo MLP possui fluxo de dados diferentes em duas etapas: i) a etapa *forward*, **propagação positiva do sinal funcional**, onde os pesos da rede são mantidos fixos e a rede recebe estímulos na entrada e apresenta os resultados na saída e ii) a etapa *backward*, **retropropagação do erro**, onde os pesos da rede são ajustados tendo por base a medida de erro na camada de saída, efetuando ajustes dos pesos sinápticos em relação a direção oposta do gradiente da função erro quadrática. Na etapa *forward*, os resultados são os valores encontrados por (3.6) para cada neurônio na saída da camada intermediária. Nesta etapa, as saídas da primeira camada intermediária serão as próximas entradas para a segunda camada intermediária, assim, sucessivamente, até a última camada, a camada de saída.

A Figura 3.12 ilustra a propagação e a retropropagação, onde o sinal de erro é propagado em sentido oposto ao de propagação do sinal funcional. Com a ocorrência sucessiva das fases *forward* e *backward*, os pesos sinápticos dos neurônios são modificados a cada iteração. Os pesos sinápticos são responsáveis por reduzir os erros produzidos nas iterações da rede neural.

Quando a solução atual de pesos estiver longe de minimizar a função erro, a variação na direção oposta ao gradiente da função erro quadrático entre duas iterações será elevada. Isto implica em aplicar passos maiores de incremento nos pesos em direção ao mínimo da função erro. Para isto, é calculado o gradiente da função erro em




Figura 3.12 - Algoritmo *backpropagation*: (a) etapa *forward* e (b) etapa *backward*.

relação aos pesos e *bias*, pois atualizando os pesos e *bias* na direção oposta ao gradiente, minimiza-se o erro. Quando a solução atual está próxima da solução desejada, todos os ajustes de peso conduzem apenas ao termo de aprendizagem da rede (SILVA et al., 2010). Como o erro é calculado apenas na camada de saída, o algoritmo *backpropagation* consegue determinar a influência do erro nas camadas intermediárias da rede.

A Figura 3.13 ilustra o funcionamento do algoritmo *backpropagation*, onde cada neurônio i refere-se a camada j , onde $j = 1$ é a camada de entrada C_E e é a fonte de dados da rede neural, $j = n$ é a camada de saída C_S da rede.




Figura 3.13 - Topologia do Perceptron múltiplas camadas.

Os pesos sinápticos $w_{i,j}$ formam a matriz de pesos referente as conexões do i -ésimo neurônio da j -ésima camada. A Figura 3.13 ilustra o fluxo na etapa *forward* das conexões direcionadas e compostas por nós. A conexão do neurônio i da camada j serve para propagar a ativação do neurônio i em outros neurônios da camada $j + 1$. Cada conexão possui o peso numérico $w_{i,j}$ associado a ela, o que determina a força e o sinal da conexão. Cada nó tem uma entrada fictícia com o peso associado w_0 escolhido aleatoriamente para inicialização da rede e cada nó realiza os cálculos de entrada $E_{i,j}$ e saída $S_{i,j}$, dados por:

$$E_{i,j} = \sum_{i=1}^n w_{i,j} \cdot S_i \quad (3.7)$$

$$S_{i,(j+1)} = g \left(w_{i,(j+1)} \cdot S_{i,n} + b_{i,(j+1)} \right) \quad (3.8)$$

onde n é o número de camadas da rede e para (3.8), $j = 1, 2, \dots, n - 1$.

O sinal de erro e no i -ésimo neurônio da camada de saída C_S , com $j = n$ na rede MLP é calculado a partir da diferença entre a saída desejada $S_{d_{i,n}}$ e o valor obtido pela saída atual $S_{i,n}$ em (3.6) e dado por (BEBIS; GEORGIPOULOS, 1994):

$$e_{i,n} = S_{d_{i,n}} - S_{i,n} \quad (3.9)$$

O valor instantâneo do erro é dado pela soma dos erros quadráticos de todos os neurônios da camada C_S , por serem os únicos neurônios visíveis, nos quais os erros podem ser calculados diretamente. Desta forma, o valor instantâneo do erro é dado por:

$$\epsilon(n) = \frac{1}{2} \sum_{i=1}^m e_{i,n}^2 \quad (3.10)$$

Considerando k o número total de padrões a serem reconhecidos no conjunto de treinamento e p o contador de iterações, o erro médio quadrático (MSE) é obtido da normalização do conjunto de treinamento, dado por:

$$\overline{\epsilon_m} = \frac{1}{k} \cdot \sum_{p=1}^k \epsilon(n) \quad (3.11)$$

A MLP é capaz de aprender por meio de exemplos e padrões apresentados a ela. A etapa de aprendizado da RNA consiste de processo iterativo de ajuste de parâmetros da rede, através dos pesos das conexões. A partir dos ajustes, a RNA guarda os melhores valores obtidos para os pesos sinápticos a partir do treinamento (DEMUTH et al., 2014). Por padrão, o treinamento da MLP é do tipo supervisionado, que tem a função de encontrar as derivadas da função erro e modificar os valores dos pesos e *bias* da RNA (SILVA et al., 2010). Para o aprendizado é importante que haja recursos suficientes para que a rede generalize, ou seja, que ela consiga reconhecer tipos diferentes de padrões aplicados a ela (GARDNER; DORLING, 1998).

Para ajustar os pesos sinápticos da camada de saída $w_{i,n}$ utiliza-se (3.12), relacionando o erro obtido $e_{i,n}^{(p)}$, onde (p) indica a iteração corrente, com a taxa de aprendizagem η e a saída anterior da rede $S_{i,n}^{(p-1)}$.

$$w_{i,j}^{(p)} \longleftarrow w_{i,j}^{(p)} + \eta \cdot e_{i,n}^{(p)} \cdot S_{i,j}^{(p-1)} \quad (3.12)$$

O ajuste dos pesos referentes às camadas intermediárias seguem a regra de formação dada por:

$$w_{i,j}^{(p-1)} \longleftarrow w_{i,j}^{(p-1)} + \eta \cdot e_{i,n}^{(p-1)} \cdot S_{i,j}^{(p-2)} \quad (3.13)$$

O ajuste dos pesos referentes à camada de entrada e a primeira camada intermediária, utiliza-se da entrada da rede para o ajuste fino, dado por:

$$w_{i,j}^{(1)} \longleftarrow w_{i,j}^{(1)} + \eta \cdot e_{i,n}^{(1)} \cdot E_{i,1} \quad (3.14)$$

3.3.4 Termo *Momentum*

Para tornar o processo de convergência da RNA mais eficiente, pode-se utilizar o método de inserção do *momentum*. Para inserção do termo *momentum*, basta inserir único parâmetro visando ponderar o quão as matrizes sinápticas foram alteradas entre duas interações sucessivas (GARDNER; DORLING, 1998). Quando o valor da taxa de *momentum* for igual a *zero*, a expressão se torna equivalente àquela do *backpropagation* convencional. Por outro lado, para valores diferentes de *zero*, o termo passa a ser relevante, sendo que tal contribuição afetará positivamente no processo de convergência da RNA (HAYKIN et al., 2009). A adição do *momentum* α_m

no processo de atualização dos pesos sinápticos é dada por:

$$\Delta w_{i,j}^{(p)} = \alpha_m \Delta w_{i,j}^{(p-1)} + \eta \cdot e_{i,n}^{(p)} \cdot S_{i,j}^{(p)} \quad (3.15)$$

Reed e Marks (1999) e Rumelhart et al. (1986) admitem que a taxa de aprendizagem η deve estar entre os valores $(0,05 \leq \eta \leq 0,75)$ e a taxa de *momentum* entre os valores $(0 \leq \eta \leq 0,9)$.

Os dados coletados e preparados para serem inseridos na rede neural devem ser separados em duas categorias: i) dados de treinamento, que são utilizados para o treinamento da rede e ii) dados de teste, que são utilizados para verificar o desempenho da rede sob condições reais de utilização (SUYKENS et al., 2002). Além desta divisão, pode-se usar também a subdivisão do conjunto de treinamento, criando o conjunto de validação, utilizado para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento, podendo ser empregado como critério de parada do treinamento (GARDNER; DORLING, 1998).

O número de **época** é definido em RNA como a quantidade de vezes necessária de apresentação da amostra para ajuste dos pesos sinápticos, ou seja, quantidade de vezes que o treinamento é interrompido e a RNA é testada com os dados de validação. Este processo deve ocorrer até que o desempenho da RNA com os dados de validação se estabilize no valor desejado do erro (KRIZHEVSKY et al., 2012).

A validação é de extrema importância, cujo propósito é avaliar a aptidão de cada estrutura da rede (SILVA et al., 2010). O método mais utilizado é a validação cruzada que é técnica da estatística clássica útil em determinar, durante o treinamento, a capacidade de generalização da rede neural. No método de validação cruzada, o conjunto total de amostras é aleatoriamente dividido em duas partes, treinamento e validação. O conjunto de treinamento é responsável por treinar todas as topologias candidatas ao problema e o conjunto de validação é aplicado para aquelas topologias que apresentarem melhores resultados. Para todo efeito, a validação pode ser repetida inúmeras vezes, garantindo seu processo de validar a rede (VINCENT et al., 2010).

A validação também é importante na prevenção de *overfitting* e *underfitting*. O *overfitting* ocorre quando há número excessivo de neurônios ou camadas na RNA para o problema que está sendo resolvido (SAMARASINGHE, 2016). Pode também ocorrer *overfitting* no treinamento, quando a rede neural é treinada com quantidades de épo-

cas além do necessário. O treinamento excessivo deixa superajustado o subconjunto de dados e o classificador tende a se adaptar a detalhes específicos da base de dados de treinamento, o que pode causar redução da taxa de acerto (ABDEL-HAMID et al., 2014).

O *underfitting* ocorre quando a rede não é treinada suficientemente para se tornar capaz de produzir resultados satisfatórios, ou seja, quando há número baixo de neurônios ou de camadas na RNA para o problema que está sendo resolvido, ficando subajustada (SRIVASTAVA et al., 2014). Pode também ocorrer *underfitting* no treinamento, quando a rede neural é treinada com quantidades de épocas abaixo do necessário.

Quando ocorre o treinamento, o conjunto de validação é apresentado de forma a ser um dos critérios de parada. Para melhor resposta do sistema, as redes devem ser testadas em funções de ativação diferentes para cada camada (PRECHELT, 1998). Nos processos da MLP, os dados de entrada são separados para treinamento, validação e teste. A configuração da rede, como número de camadas, número de neurônios em cada camada, parâmetros do algoritmo de treinamento e funções de ativação normalmente são escolhas realizadas empiricamente (KULIK, 2015).

A essência do aprendizado da rede neural através do algoritmo de retropropagação do erro consiste em realizar o mapeamento, através dos ajustes dos pesos sinápticos dos pares entrada/saída de vetores. A rede aprende o suficiente com esta associação para ser capaz de encontrar associações válidas para vetores de entradas desconhecidos (DEMUTH et al., 2014). A rede deve, portanto, ter capacidade de generalizar o conhecimento aprendido aplicando-o em novas situações. A Figura 3.14 ilustra o fluxograma de funcionamento da rede neural MLP.

3.4 Codificação de classes

A camada de saída é responsável por classificar os padrões estipulados pela MLP. Em suma, qualquer problema de classificação pode ser resolvido por combinações lógicas, do tipo *and* ou *or*, em relação as regiões que foram definidas pelos neurônios (GRITSENKO et al., 2016). As combinações lógicas quando mapeadas conjuntamente, formam regiões (ou classes) distintas.

Um dos métodos de classificação é o de codificação sequencial, que utiliza combinação binária. A Tabela 3.1 apresenta a matriz de saída deste método, onde V_{S_1} a V_{S_4} são os valores de saídas, N_1 e N_2 são os neurônios da camada de saída e em cada linha




Figura 3.14 - Fluxograma de funcionamento da rede Perceptron múltiplas camadas.

são apresentadas classes distintas.

Tabela 3.1 - Codificação sequencial.

	N_1	N_2	Classe
V_{S_1}	0	0	A
V_{S_2}	0	1	B
V_{S_3}	1	0	C
V_{S_4}	1	1	D

A quantidade de classes Q_{c_s} proveniente deste método é dado por:

$$Q_{c_s} = 2^{(Q_{n_s})} \quad (3.16)$$

onde Q_{n_s} representa o quantidade de neurônios da camada de saída.

O método de codificação sequencial é aplicado com a justificativa de reduzir a quantidade de neurônios na camada de saída. A Tabela 3.1 e a expressão (3.16) informam que para dois neurônios podem ser construídas até quatro classes distintas. Hampshire e Pearlmutter (1991) afirmam que este método aumenta a necessidade de recursos computacionais.

Outro método utilizado é o **codificação c-classes**, que associa a saída de cada neurônio diretamente com sua classe correspondente (SILVA et al., 2010). A Tabela 3.2 apresenta quatro classes pela codificação c-classes, onde V_{S_1} a V_{S_4} são os vetores de saídas, N_1 a N_4 são os neurônios da camada de saída e em cada linha são apresentadas classes distintas.

Tabela 3.2 - Codificação c-classes.

	N_1	N_2	N_3	N_4	Classe
V_{S_1}	1	0	0	0	A
V_{S_2}	0	1	0	0	B
V_{S_3}	0	0	1	0	C
V_{S_4}	0	0	0	1	D

Na codificação c-classes, a quantidade de classes reconhecidas é igual a de neurônios na camada de saída e, por consequência, apresenta número maior de neurônios na camada de saída, quando comparado com o método de codificação sequencial. Quando se utiliza o método c-classes, os valores de saída $S_{i,n}$ dado por (3.6) podem

ser pós-processados como:

$$S_{pp} = \begin{cases} 1, & \text{se } S_{i,n} \geq \lim^{sup} \\ 0, & \text{se } S_{i,n} < \lim^{sup} \end{cases} \quad (3.17)$$

onde S_{pp} representa a saída pós-processada e $\lim^{sup}$ representa o limite superior que a função de ativação pode assumir.

3.5 Considerações

O conceito de aquisição e processamento de sinais pode ser utilizado para dispositivos e aplicações em diversos contextos. O principal objetivo ao adquirir e processar dados é usufruir dos melhores dados dentro do arranjo de informações e chegar ao resultado final com eficiência e otimização do uso de recursos. O conceito de redes neurais artificiais é primordial para usufruir de cálculos e desenvolvimento de programação capaz de reconhecer padrões em melhor taxa de acertos. Após discutir sobre língua de sinais, aquisição, processamento e redes neurais artificiais, o próximo capítulo descreverá a metodologia a ser utilizada.

CAPÍTULO 4

METODOLOGIA

É apresentado neste capítulo a metodologia para projetar e desenvolver quatro dispositivos capazes de identificar configuração e movimento das mãos, com o propósito de verificar qual possui melhor desempenho para reconhecimento da língua de sinais e tradição para a linguagem escrita. Descreve o sistema embarcado, a distribuição e arranjo dos sensores no dispositivo e os diagramas de conexão e esquemas elétricos. Apresenta ainda a aplicação da rede neural com o tratamento de dados, teste e validação.

4.1 Leiaute do dispositivo

Para o desenvolvimento do trabalho é necessário encontrar/construir a luva com o melhor leiaute para receber os sensores, de forma a não prejudicar a produção dos movimentos dos dedos. São necessários testes para encontrar a melhor disposição dos sensores na luva, a fim de compreender todos os dedos, dorso e punho. Desenvolve-se a programação do microcontrolador para realizar a aquisição dos dados nos sensores e constrói-se a rede neural para reconhecimento dos padrões que foram adquiridos dos dados coletados dos sensores. Na sequência, realiza-se a validação dos resultados, validando o dispositivo proposto.

Para construção do dispositivo, existe a necessidade de definir o leiaute. Este leiaute deve partir de luva flexível com tamanho a definir. Esta luva deve vestir à mão de forma que não atrapalhe a realização das configurações e movimentos. O leiaute ainda deve levar em conta a disposição de sensores e cabos de conexão.

O material para construção do dispositivo deve ser leve, não espesso, consistente e ajustável a mão. É desejável que os sensores e cabos de conexão sejam acoplados fora das articulações, diminuindo as possibilidades de quebra e, consequentemente a interrupção na comunicação entre o dispositivo e o computador. Os cabos de conexão devem ser flexíveis o suficiente para não atrapalhar na gesticulação. Os sensores devem ficar o mais distante um do outro, pois o amontoamento pode atrapalhar nos movimentos.

O leiaute não deve ser personalizado, ou seja, o dispositivo deve ser vestido em qualquer mão que tenha o mesmo tamanho. Os sensores devem ser localizados sobre o dispositivo de tal forma que fiquem firmes e estáveis, não se deslocando na ocorrência de movimentos bruscos. Caso o dispositivo proporcione alguma dificuldade na

produção dos movimentos, isto acarretará ruídos nos sinais coletados nos sensores, produzindo padrões indesejáveis e não realizando o correto reconhecimento dos movimentos. A Figura 4.1 apresenta o fluxograma do processo de desenvolvimento dos dispositivos para reconhecimento de gestos da língua de sinais.




Figura 4.1 - Fluxograma para desenvolvimento de tecnologia para reconhecimento de gestos da língua de sinais.

4.2 Construção dos dispositivos

Para testes de desempenhos entre os sensores, são desenvolvidos quatro protótipos: Protótipo P_1 , Protótipo P_2 , Protótipo P_3 e Protótipo P_4 . Na construção destes protótipos, leva-se em consideração os principais parâmetros fonológicos para o reconhecimento da língua de sinais: i) ponto de articulação, ii) configuração da mão,

iii) orientação e iv) movimentos. A Figura 4.2 e Figura 4.3 ilustram os parâmetros fonológicos da língua de sinais.




Figura 4.2 - Parâmetro fonológico da língua de sinais: ponto de articulação.




Figura 4.3 - Parâmetros fonológicos da língua de sinais: (a) configuração de mão, (b) orientação e (c) movimento.

A Figura 4.2 ilustra o ponto de articulação, que é a área onde incide o gesto e na Figura 4.3(a) é ilustrada a configuração da mão, que trata do formato da mão no gesto e permite verificar o alinhamento do punho e a variação da configuração ao longo da execução do gesto. Na Figura 4.3(b) é ilustrada a orientação da mão, que designa a direção em que a mão produz o movimento do gesto e por fim, na Figura 4.3(c) é ilustrado o movimento referente ao trajeto das mãos durante o gesto.

O conhecimento dos parâmetros fonológicos auxilia no posicionamento dos sensores

sobre o leiaute dos protótipos. Na construção dos protótipos são utilizados os sensores de flexão para verificar a abertura e curvatura dos dedos, acelerômetros para identificar o movimento e o direcionamento da mão e giroscópios para mapear a rotação e direção do movimento.

Com o propósito de comparar a resposta encontrada pelos sensores nos dispositivos, são desenvolvidos os protótipos com diferentes sensores em diferentes quantidades. Todos os protótipos desenvolvidos são capazes de averiguar gestos estáticos e os Protótipo P_2 , Protótipo P_3 e Protótipo P_4 averigam movimento e orientação. O Protótipo P_2 verifica movimento e orientação do dorso da mão e punho. O Protótipo P_3 contempla movimento e orientação do dorso e dos dedos da mão e o Protótipo P_4 verifica movimento e orientação dos dedos e do punho.

O Protótipo P_1 contém cinco sensores de flexão distribuídos sobre o seu leiaute, como ilustra a Figura 4.4(a). A Figura 4.4(b) ilustra o diagrama de conexão do Protótipo P_1 , onde de S_{f1} a S_{f5} são sensores de flexão e M_c é o microcontrolador. O Protótipo P_1 é encontrado no mercado trocando o sensor de flexão por sensores baseados em fibra óptica, tornando-o oneroso.




Figura 4.4 - Protótipo P_1 : (a) leiaute e (b) diagrama de conexão.

O Protótipo P_2 contém cinco sensores de flexão e dois módulos com acelerômetro e giroscópio (MEMS), como ilustra a Figura 4.5(a). A Figura 4.5(b) ilustra o diagrama de conexão de P_2 , onde de S_{f1} a S_{f5} são sensores de flexão, M_c é o microcontrolador, A_{g1} e A_{g2} são os MEMS. O posicionamento dos MEMS considera o

deslocamento do dorso da mão em relação ao punho.




Figura 4.5 - Protótipo P_2 : (a) leiaute e (b) diagrama de conexão.

O Protótipo P_3 contém cinco sensores de flexão e oito MEMS. Os MEMS estão distribuídos sobre as pontas dos dedos, base dos dedos indicador e anelar e dorso da mão, como ilustrado na Figura 4.6(a). A Figura 4.6(b) ilustra o diagrama de conexão de P_3 , onde de S_{f1} a S_{f5} são sensores de flexão, M_c é o microcontrolador e de A_{g1} a A_{g8} são os MEMS. O posicionamento dos MEMS considera o deslocamento do dorso da mão e o deslocamento das pontas dos dedos em relação ao punho.




Figura 4.6 - Protótipo P_3 : (a) leiaute e (b) diagrama de conexão.

O Protótipo P_4 é semelhante ao Protótipo P_3 , no entanto, ele contém oito MEMS e nenhum sensor de flexão. A Figura 4.7(a) ilustra o Protótipo P_4 e a Figura 4.7(b) ilustra o diagrama de conexão do Protótipo P_4 , onde M_c é o microcontrolador e de A_{g1} a A_{g8} são os MEMS. Os sensores de flexão são retirados no intuito de mensurar sua contribuição para o dispositivo.




Figura 4.7 - Protótipo P_4 : (a) leiaute e (b) diagrama de conexão.

4.3 Aquisição dos dados

Após os protótipos prontos e testados a conexão, inicia-se a coleta de dados e construção da base de dados necessária para treinamento da rede neural. Os indivíduos que utilizam os protótipos e gesticulam para a construção da base de dados devem conhecer a língua de sinais, de forma a realizar corretamente os gestos. Ao vestir o protótipo, este indivíduo deve colocá-lo adequadamente, ajustando-o até o final dos dedos.

Cada gesto faz com que cada sensor produza valor de saída diferente. Cada valor de saída produzido por cada sensor forma o vetor contendo o gesto. Os sensores de flexão produzem sinais analógicos nos seus resistores variáveis e para obter os valores referentes a variação resistiva deve-se implementar divisores de tensão. A Figura 4.8 ilustra o esquema elétrico para coleta do sinal de saída dos sensores de flexão, onde V_{in} é a tensão de alimentação, R_{S_f} é a resistência do sensor de flexão e R é o resistor responsável por gerar a tensão de saída V_{out} proporcional a tensão V_{in} . A tensão de saída V_{out} é dada por (4.1) e é registrada na entrada analógica E_{da1}

do microcontrolador M_c .

$$V_{out} = \frac{R}{R + R_{Sf}} \cdot V_{in} \quad (4.1)$$




Figura 4.8 - Esquema elétrico para coleta de dados nos sensores de flexão.

O microcontrolador recebe os sinais analógicos e converte em sinais digitais. A resolução do conversor R_p é expressa pela relação entre a tensão de referência do microcontrolador V_{ref} e a quantidade de *bits* n_b do conversor, dado por:

$$R_p = \frac{V_{ref}}{2^{n_b}} \quad (4.2)$$

Para realizar a leitura dos sinais dos MEMS é necessária comunicação I2C entre microcontrolador e MEMS. Os MEMS possuem recurso de processamento digital de movimento que é capaz de adquirir e processar os movimentos nos eixos x , y e z do acelerômetro e do giroscópio no próprio sensor. Além disto, possuem internamente conversores analógico/digital de 16 *bits* de resolução para cada canal e memória de 1024 *bytes* para armazenamento temporário dos sinais enquanto faz a comunicação.

A Figura 4.9 ilustra o esquema elétrico para coleta do sinal de saída dos MEMS. Para enviar os dados para o microcontrolador é necessário estabelecer qual dos MEMS fará a comunicação. Para isto, o microcontrolador envia sinais digitais de controle para as entradas S_{C1} e S_{C2} do demultiplexador que, por conseguinte, envia sinais para as portas AD_0 dos MEMS. A porta AD_0 define o endereçamento I2C dos

MEMS, desta forma, o demultiplexador manda sinal *zero* para o AD_0 do MEMS que fará a comunicação e envia 1 para os demais MEMS.




Figura 4.9 - Esquema elétrico para coleta de dados dos MEMS.

Os dados do sensor de flexão, recebidos pela porta analógica do microcontrolador, são normalizados. Além disto, é desenvolvida rotina para estabelecer os valores iniciais (*offset*) dos MEMS, de forma a estabelecer estado de inicialização e, a partir dos dados coletados dos MEMS, calcula-se: a) os ângulos de aceleração dos eixos x , y e z dos acelerômetros e b) o valor do giro em graus por segundo para os eixos x , y e z dos giroscópios.

Os sensores captam os gestos produzidos nos protótipos e cada gesto atua diferentemente sobre cada sensor. Após a coleta dos valores produzidos pelos sensores, constrói-se o vetor V_g , que representa cada gesto, dado pela concatenação dos vetores S_s , A_s .

$$S_s = [S_{f_1}, \dots, S_{f_5}] \quad (4.3)$$

$$A_s = [(A_{x_1}, A_{y_1}, A_{z_1}, \dots, A_{x_K}, A_{y_K}, A_{z_K}), (G_{x_1}, G_{y_1}, G_{z_1}, \dots, G_{x_K}, G_{y_K}, G_{z_K})] \quad (4.4)$$

$$V_g = [S_s, A_s] \quad (4.5)$$

onde K é o número de sensores, S_s é o vetor com os valores obtidos dos sensores de flexão S_f , A_s é o vetor com os valores obtidos dos MEMS A_g . As variáveis A_x , A_y e A_z e G_x , G_y e G_z são os valores nas posições x , y , e z dos acelerômetros e giroscópio, respectivamente. No caso do Protótipo P_1 que não têm os MEMS, o vetor A_s é suprimido de V_g e no caso do Protótipo P_4 , que não têm os sensores de flexão, o vetor S_s é suprimido.

A partir do vetor V_g é possível construir a matriz contendo as configurações, que é utilizada na rede neural artificial. Cada linha da matriz de configuração contém a repetição do mesmo gesto. Logo, se o gesto for repetido τ vezes, a matriz de configuração terá τ linhas. A matriz de configurações é dada por:

$$Q_{i,j} = \begin{bmatrix} V_{g1,j} \\ V_{g2,j} \\ \vdots \\ V_{g\tau,j} \end{bmatrix} \quad (4.6)$$

onde i é o contador das linhas, $i = 1, 2, \dots, \tau$ e τ é o número de vezes que o mesmo gesto é reproduzido e j é o contador relacionado as colunas da matriz $Q_{i,j}$ e refere-se a quantidade de sensores (sinais coletados) no vetor V_g .

A partir da matriz $Q_{i,j}$ é possível construir a matriz $M_{E_{i,j}}$ que é a entrada da RNA. A matriz $M_{E_{i,j}}$ dada por (4.7) é produzida a partir da concatenação de todos os possíveis gestos armazenados nas matrizes de configuração $Q_{i,j}$. O valor T é: a multiplicação da quantidade de vezes que determinado gesto foi repetido pelo número de gestos, e indica a quantidade de linhas da matriz $M_{E_{i,j}}$.

$$M_{E_{i,j}} = \begin{bmatrix} Q_{1,j} \\ Q_{2,j} \\ \vdots \\ Q_{T,j} \end{bmatrix} \quad (4.7)$$

Quando o protótipo é conectado à porta serial do computador e a rotina para aquisição de dados é inicializada, são realizados testes para verificar a comunicação. Se há comunicação, a rotina computacional apresenta mensagem de confirmação e os gestos devem ser produzidos. Se não, o processo será reinicializado até que ocorra a comunicação do protótipo com o computador.

A rotina computacional reconhece o início e término do gesto quando há variação dos sinais entregues. Caso o sinal de entrada esteja estático e em seguida ocorre variação, é verificado o início do gesto. Por conseguinte, aguarda a nova variação dos sinais de entrada e finaliza o gesto. Novos gestos podem ser produzidos após a inserção do gesto anterior na matriz $Q_{i,j}$.

A matriz $M_{E_{i,j}}$ que armazena os sinais estáticos, pode armazenar a dinâmica de cada gesto. Assim, para realizar a coleta de forma dinâmica, após a identificação do movimento, guarda-se os primeiros valores medidos nos sensores no tempo t_0 . A segunda coleta é realizada no tempo t_{Ag} , que é o tempo de aquisição do MEMS. Após as duas primeiras coletas, é realizada a última coleta quando não ocorrer mais variações nos valores obtidos dos MEMS. Esta terceira e última coleta é realizada no tempo t_δ . Desta forma, a matriz $M_{E_{i,j}}$ pode ser reescrita considerando a dinâmica dos gestos, dada por:

$$M_E(i, j, \delta) = \begin{bmatrix} Q_{1,j,\delta} \\ Q_{2,j,\delta} \\ \vdots \\ Q_{T,j,\delta} \end{bmatrix} \quad (4.8)$$

onde a nova matriz $M_E(i, j, \delta)$ é a matriz tridimensional, contendo a dinâmica dos gestos no tempo, como ilustrado na Figura 4.10.

Na Figura 4.10, t_0 é o tempo da primeira coleta, t_{Ag} é o tempo da segunda coleta e t_δ o tempo da terceira coleta, i representa o contador de linhas, que é a quantidade de vezes que o gesto é realizado, j representa o contador de colunas da matriz $Q_{i,j}$,




Figura 4.10 - Matriz tridimensional para coleta da dinâmica dos gestos.

que é a quantidade de sinais coletados no vetor V_g .

4.4 Processamento dos dados

Após a aquisição dos dados, é necessário realizar a normalização da matriz $M_{E_{i,j}}$, na tentativa de diminuir os problemas referentes ao processamento e melhorar a eficiência da RNA. No processo de normalização, dado por (4.9), as variáveis devem ser pré-processadas de modo que o valor médio calculado sobre todo o conjunto de treinamento seja próximo a *zero* e que todo conjunto de dados seja limitado aos valores (O_{min}, O_{max}) .

$$O_n = \frac{(O_{max} - O_{min}) \cdot (I - I_{min})}{(I_{max} - I_{min}) + O_{min}} \quad (4.9)$$

onde O_n é o dado normalizado, I é o dado a ser normalizado, O_{max} é o valor máximo de saída, O_{min} é o valor mínimo de saída, I_{max} é o valor máximo de entrada e I_{min} é o valor mínimo de entrada.

Os erros obtidos no treinamento da MLP são calculados pela diferença entre valor desejado para saída $S_{d_{i,n}}$ e valor obtido pela saída atual $S_{i,n}$, dado por (3.9). Para obter os vetores de valor desejado para saída é utilizado o método de codificação c -classes.

Para cada classe a ser reconhecida é gerado o vetor binário de saída desejado $S_{d_{i,n}}$, que é construído utilizando o método c -classes. O vetor de saída $S_{i,n}$ da RNA é composto dos valores obtidos nos neurônios da camada de saída C_S . Nas etapas de treinamento e validação da rede, o vetor $S_{i,n}$ é normalizado utilizando (3.17) e comparado com $S_{d_{i,n}}$, produzindo o erro $e_{i,n}$ em (3.9).

Para a construção da MLP, a matriz de configuração deve ser dividida em três partes referentes as etapas: i) treinamento, ii) validação e iii) testes. A literatura indica que o conjunto de dados para a etapa de treinamento deve apresentar maior porcentagem dos dados coletados, de forma a agregar características de cada gesto, enquanto o conjunto de dados para as etapas de validação e testes devem conter a mesma quantidade. Após a escolha do percentual de cada parcela, as amostras (vetor V_g) que serão utilizadas para treinamento e validação são escolhidas randomicamente entre as linhas da matriz $Q_{i,j}$.

Para determinar a topologia da MLP, são realizados ensaios que modificam: i) as funções de ativação $g(\cdot)$ para cada camada, ii) a taxa de aprendizagem η_{CEI} entre as camadas de entrada C_E e intermediária C_I , iii) a taxa de aprendizagem η_{CIS} entre as camadas intermediária C_I e de saída C_S , iv) a quantidade de neurônios m na camada intermediária e v) a quantidade de amostras t na camada de entrada para etapa de treinamento. Os ensaios são executados sequencialmente e o melhor resultado apresentado pelo experimento é utilizado, sendo que o melhor resultado está relacionado a maior média de acertos da RNA.

Os ensaios são realizados empiricamente e divididos em duas etapas. Na primeira etapa dos ensaios, utiliza-se o conjunto de teste coletados nas matrizes $Q_{i,j}$ e são definidos os limites máximos e mínimos para os parâmetros η_{CEI} , η_{CIS} , m na camada intermediária e o valor de t . Na segunda etapa, após verificar os melhores resultados obtidos, são realizados testes com o usuário vestindo o protótipo e conectando-o ao computador.

4.5 Validação

A etapa de validação consiste em qualificar e quantificar os resultados e é dividida em duas partes: i) validação dos protótipos e ii) validação da rotina computacional e RNA. Na validação do protótipo é verificada a **eficácia**, que mensura o quão próximo do objetivo proposto o protótipo está e a **eficiência**, que mede a quantidade de acerto que ele produz dentro do proposto para o protótipo.

A eficácia é medida através de testes realizados sem a conexão do protótipo à rotina computacional, apenas analisando os gestos e verificando se as respostas são diferentes para cada gesto. A eficiência é medida validando a rotina computacional e a RNA. Quanto maior for a quantidade de acerto do protótipo em determinado gesto, maior será a sua eficiência.

Ao vestir o protótipo na mão e conectá-lo ao computador, a rotina computacional deve validar se está recebendo todos os sinais enviados pelo protótipo. Para isto, identifica e abre a porta serial na qual o protótipo está conectado e, se confirmado, inicia a comunicação.

Para validar a MLP é necessário verificar e comparar resultados obtidos para diferentes topologias assumidas para treinamento e validação. Verifica-se a média da taxa de acertos utilizando diferentes parâmetros separadamente e sequencialmente. Ao final, a topologia da MLP que assumir maior média de acertos para o conjunto de teste é utilizada.

A validação do protótipo encerra-se quando: i) reconhecer separadamente caracteres específicos, estáticos e dinâmicos, ii) treinar novos gestos/palavras com mesma topologia da MLP e iii) reconhecer separadamente cada palavra nova treinada.

4.6 Considerações

Este capítulo descreve sobre a construção, aquisição e processamento de dados para a criação dos protótipos de reconhecimento de caracteres da língua de sinais. Apresenta os procedimentos para validação dos dispositivos construídos e com base na descrição metodológica, realiza-se a coleta de dados, produzindo o próximo capítulo com os resultados obtidos.

CAPÍTULO 5

RESULTADOS

Neste capítulo são apresentados os resultados obtidos utilizando a metodologia proposta. Cada dispositivo é testado e os resultados são analisados e comparados. Para isto, o capítulo foi dividido em quatro partes: i) leiaute, componentes e construção dos dispositivos, ii) construção da base de dados, iii) tratamento dos dados para a rede neural artificial e iv) validação do dispositivo e da rede neural artificial.

5.1 Leiaute, construção dos dispositivos e componentes

Os Protótipo P_1 , Protótipo P_2 , Protótipo P_3 e Protótipo P_4 foram idealizados para obtenção de respostas mais precisas na ordem de construção, ou seja, a resposta do Protótipo P_2 mais precisa que a resposta do Protótipo P_1 , a resposta do Protótipo P_3 mais precisa que a resposta do Protótipo P_2 e a resposta do Protótipo P_4 mais precisa que a respostas dos protótipos anteriores. Para montagem dos protótipos foram adquiridas luvas com tamanho médio, maleáveis e com ajuste na palma da mão.

Os Protótipo P_1 , Protótipo P_2 e Protótipo P_3 são construídos com luvas finas de tecido composto por poliéster e elastano. Utilizou-se velcro para acoplar os MEMS e fiação, proporcionando ajuste e firmeza do dispositivo na mão. Para o Protótipo P_4 , foi fabricada luva em neoprene e adaptado bolsos específicos para alocação dos MEMS e fios. A Figura 5.1 e a Figura 5.2 apresentam os quatro protótipos construídos e a Figura 5.3 apresenta a adaptação dos bolsos para alocar os sensores e passagem dos fio no Protótipo P_4 .

Na Figura 5.1(a) é apresentado o Protótipo P_1 com a indicação dos cinco sensores de flexão representados por S_{f_1} a S_{f_5} . A mesma disposição dos sensores de flexão do Protótipo P_1 é utilizada para os Protótipo P_2 e Protótipo P_3 . A Figura 5.1(b) apresenta o Protótipo P_2 que possui cinco sensores de flexão e dois MEMS, onde os MEMS são indicados por A_{g_1} e A_{g_2} . Na Figura 5.2(a) é apresentado o Protótipo P_3 que possui cinco sensores de flexão e oito MEMS indicados de A_{g_1} a A_{g_8} .

Por fim, na Figura 5.2(b) é apresentado o Protótipo P_4 , que possui oito MEMS indicados por A_{g_1} a A_{g_8} e não possui sensores de flexão. A Figura 5.3 apresenta os bolsos e costuras realizadas no Protótipo P_4 para alocação dos MEMS e passagem da fiação. Os bolsos possuem tamanho suficiente para os MEMS não se deslocarem, ficando fixo durante os movimentos e não prejudicando a gesticulação.




Figura 5.1 - Dispositivos construídos: (a) Protótipo P_1 e (b) Protótipo P_2 .




Figura 5.2 - Dispositivos construídos: (a) Protótipo P_3 e (b) Protótipo P_4 .

A disposição dos sensores para cada dispositivo foi estudada para obter maior precisão na captura dos sinais. Os sensores de flexão foram acoplados aos protótipos de forma que estes atinjam o comprimento total dos dedos, evitando esforços que romperiam os contatos do sensor. O tamanho do *chip* do MEMS foi escolhido de forma a não prejudicar os movimentos dos dedos, na gesticulação. Na Figura 5.3 observa-se os MEMS fora dos bolsos na parte superior da luva.

A placa de aquisição foi construída para acoplar o microcontrolador, demultiplexa-



Figura 5.3 - Bolsos de alocação dos MEMS e fios.

dor e fiação, que é interligada aos sensores de cada protótipo. Para a construção dos protótipos são utilizados: i) placa **Arduíno Nano**, que é plataforma de prototipagem eletrônica de *hardware* livre com placa única, projetada com microcontrolador Atmel Atmega 328 com suporte de entrada/saída embutido. É ferramenta acessível no mercado e de baixo custo, ii) **circuito integrado (CI) 74HC138**, que opera em total sincronia com os demais componentes do sistema, recebendo sinais eletrônicos e ordenando as ações, suas características principais são: demultiplexador, registrador de deslocamento, compacto, dezesseis terminais, acessível no mercado e baixo custo e iii) **cabos AWG 22** e conectores. A dimensão da placa foi determinada de forma que se acoplasse ao pulso. O CI 74HC138 foi conectado abaixo da placa Arduíno Nano, para melhor utilização de espaço.

Os sensores utilizados para a construção dos protótipos são: i) sensor de flexão, com 11,4cm de comprimento, e ii) módulo sensor GY-521, que possui um acelerômetro e um giroscópio de alta precisão em circuito integrado, MPU-6050. A comunicação do módulo GY-521 com o microcontrolador utiliza interface I2C, por meio dos pinos *SCL* e *SDA* do sensor. O sensor de flexão é conectado em 5V e o módulo GY-521 em 3,3V, estas tensões são disponibilizadas pela placa Arduíno Nano.

Utiliza-se resistores *pull-down* com valores de 10k Ω nos sensores de flexão e os MEMS são conectados nas saídas do demultiplexador. A Figura 5.4 apresenta o diagrama esquemático entre a placa Arduíno Nano, CI 74HC138, oito MEMS, referente ao Protótipo P_3 .

A conexão com maior quantidade de MEMS deve ser realizada interligando o pino AD_0 às respectivas saídas do demultiplexador (NEXPERIA, 2015). A configuração do GY-521 é realizada por meio da escrita em registradores e a velocidade de comunicação é de até 400Hz por meio da interface I2C (INVENSENSE, 2016).




Figura 5.4 - Diagrama esquemático das conexões dos componentes na construção do Protótipo P_3 .

O processamento digital de movimento (DMP), disponível no módulo GY-521, possui algoritmos de detecção dos movimentos nos eixos dos sensores que enviam sinais digitais para o microcontrolador. A partir destes sinais, são calculados os ângulos de aceleração dos eixos x , y e z do acelerômetro e o valor do giro em graus por segundo do giroscópio. Os sinais coletados pelo sensor de flexão são enviados às portas analógicas do microcontrolador, que possuem conversor A/D. Assim, os sinais de tensão são convertidos em sinais digitais e mapeados no range escolhido para cada sensor.

5.2 Construção da base de dados

Para a construção da base de dados, os protótipos foram conectados ao computador por porta universal (*Universal Serial Bus* – USB), como ilustra a Figura 5.5. Após conectado o cabo na porta USB, a comunicação é confirmada através de mensagem para inicialização da aquisição. A base de dados foi construída por dois indivíduos com conhecimento em Libras. Repetiu-se 500 vezes o mesmo gesto, coletando 500 vetores V_g para cada gesto realizado. A Figura 5.6 ilustra alguns dos parâmetros estáticos que foram gesticulados para a construção da base de dados.

A Tabela 5.1 e a Tabela 5.2 dispõem os dados coletados dos sensores (vetores V_g) para os gestos estáticos apresentados na Figura 5.6 pelos Protótipo P_1 e Protótipo P_3 . São apresentados apenas os dados obtidos dos Protótipo P_1 e Protótipo P_3 por serem os que contém a menor e a maior quantidade de sensores, respectivamente.



Figura 5.5 - Protótipo P_4 conectado ao computador.




Figura 5.6 - Gestos: (a) número **zero**, (b) número **1**, (c) número **2**, (d) número **3** e (e) número **4**.

Tabela 5.1 - Sinais de saída do Protótipo P_1 para os gestos estáticos **zero**, **1**, **2**, **3** e **4**.

Sinal sensor	Gesto				
	zero	1	2	3	4
S_{f_1}	448	596	609	416	473
S_{f_2}	352	350	532	539	531
S_{f_3}	232	196	226	401	387
S_{f_4}	280	270	290	453	440
S_{f_5}	59	51	67	80	123

Observa-se na Figura 5.6 e na Tabela 5.1 que os dados obtidos para cada gesto são distintos, validando a eficácia do Protótipo P_1 . Verifica-se que o sinal do sensor de flexão S_{f_5} apresenta valores diferentes para o gesto **4** quando comparado aos outros gestos. Isto se justifica por ser o único gesto da Figura 5.6 em que o dedo mínimo está estendido. A Tabela 5.2 corrobora a eficácia do Protótipo P_3 para diferentes gestos e neste caso, a avaliação é precisa pois, há sinais que variam com os eixos x , y e z para os acelerômetros e giroscópios.

Na Tabela 5.2, verifica-se que os dados obtidos para cada gesto são distintos, ao observar os sinais do sensor A_{x_1} , acoplado a extremidade do dedo polegar, é verificado que para os gestos **1** e **2** os valores são semelhantes. Isto ocorre por serem os dois

Tabela 5.2 - Sinais de saída do Protótipo P_3 para os gestos **zero**, **1**, **2**, **3** e **4**.

Sinal sensor	Gesto				
	zero	1	2	3	4
S_{f1}	453	593	608	419	476
S_{f2}	355	347	532	538	537
S_{f3}	228	197	221	399	392
S_{f4}	283	266	291	453	446
S_{f5}	61	53	65	83	125
A_{x1}	43	-143	-151	0	41
A_{y1}	5	7	97	-142	-119
A_{z1}	88	0	30	42	21
A_{x2}	127	-81	-125	-108	-102
A_{y2}	-112	-155	-49	-43	-37
A_{z2}	89	-19	36	71	73
A_{x3}	0	-133	-163	-163	-158
A_{y3}	-161	-157	-81	0	0
A_{z3}	83	-58	40	54	62
A_{x4}	2	-148	-162	-122	-152
A_{y4}	-162	-162	-55	3	0
A_{z4}	83	1	35	64	20
A_{x5}	-56	-152	-153	-148	-148
A_{y5}	43	-4	27	20	24
A_{z5}	138	-60	-64	-63	-57
A_{x6}	68	-101	-145	-108	-116
A_{y6}	132	-11	41	47	57
A_{z6}	79	130	54	118	95
A_{x7}	-32	-140	-154	-148	-159
A_{y7}	139	-22	-16	-47	-18
A_{z7}	91	66	42	-6	-6
A_{x8}	-18	-142	-144	-135	-152
A_{y8}	157	49	50	25	21
A_{z8}	-35	57	49	73	43
G_{x1}	-1	0	-4	0	-2
G_{y1}	0	5	0	2	2
G_{z1}	-4	-10	0	3	0
G_{x2}	-1	-1	-1	0	-3
G_{y2}	0	-3	0	1	4
G_{z2}	0	-7	-1	2	-3
G_{x3}	-10	0	-7	0	-5
G_{y3}	0	0	0	0	5
G_{z3}	0	0	-1	1	-8
G_{x4}	0	-1	0	0	0
G_{y4}	0	-2	0	-25	0
G_{z4}	-1	0	-2	4	-5
G_{x5}	5	-3	25	15	0
G_{y5}	0	2	35	10	2
G_{z5}	1	0	-11	-18	-9
G_{x6}	-1	-2	-13	-7	-13
G_{y6}	-2	-2	-24	-22	-1
G_{z6}	-4	0	-12	2	-7
G_{x7}	-3	-5	6	8	-3
G_{y7}	5	4	3	3	4
G_{z7}	2	0	-15	-7	-14
G_{x8}	-7	-6	2	9	-11
G_{y8}	15	3	-5	2	0
G_{z8}	1	-3	-2	-8	-8

gestos realizados com o dedo polegar estendido. Este é apenas um padrão reconhecido de um sensor, no entanto, isto ocorre para cada sensor em cada diferente gesto. Ainda na Tabela 5.2 é possível observar que os sinais G relativos aos giroscópios possuem variações em seus valores no intervalo de -30 a 30 para os gestos estáti-

cos. Esta informação é relevante uma vez que a maioria dos gestos em Libras são dinâmicos. Desta forma, se a variação em todos os valores de todos os G estiverem fora do intervalo -30 e 30 , o gesto é dinâmico.

A Tabela 5.3 dispõe as médias $\bar{X}$ e o desvio padrão σ dos sinais obtidos nos sensores para a produção dos gestos **zero**, **3** e **4**, dispostos na Tabela 5.2. Na tentativa de averiguar os sinais obtidos dos gestos dinâmicos (com movimento como rotação), utilizou-se o Protótipo P_3 . Foram analisados dois gestos distintos, **i** e **j** que possuem mesma configuração de mão, porém a letra **j** possui gesticulação dinâmica. Para a coleta de dados dos gestos dinâmicos, foi considerado o tempo t_0 para o início da leitura do sinal. Se após o tempo t_0 os valores de G sofrerem variações no intervalo $-30 \leq G \leq 30$, o gesto é estático e coleta-se a primeira leitura. Se houver variações e estas estiverem além do intervalo $-30 \leq G \leq 30$, o gesto é dinâmico e coleta-se a leitura intermediária.

Na Figura 5.7, são apresentados os gestos **i** e **j** e na Tabela 5.4 estão dispostos os valores obtidos dos dois sinais **i** e **j** para duas repetições (coletas do mesmo gesto). Observa-se na Tabela 5.4 que os valores de G estão no intervalo $-14 \leq G \leq 15$ para o gesto **i**. Para o gesto **j**, o intervalo de variação é de $-286 \leq G \leq 286$. Desta forma, é possível reconhecer os gestos **i** e **j**, mesmo sendo o gesto **j** dinâmico. Observa-se ainda na Tabela 5.4 que os valores dos sinais coletados dos sensores S_{f_1} até A_{y_5} são semelhantes em ambos os gestos **i** e **j**, por apresentarem mesma configuração de mão.




Figura 5.7 - Gestos: (a) letra **i** e (b) letra **j**.

5.3 Tratamento dos dados para a rede Perceptron múltiplas camadas

Para auxiliar o processamento de dados e melhorar a eficiência da MLP é necessário normalizar os sinais coletados dos sensores. Desta forma, todas as matrizes de configuração $Q_{i,j}$ foram normalizadas utilizando a normalização tangente hiperbólica no intervalo $(-1, 1)$. A Tabela 5.5 dispõe os valores dos sinais de saída e dos dados normalizados para o gesto **zero** utilizando o Protótipo P_1 . A Tabela 5.5 é

Tabela 5.3 - Média e desvio padrão dos sinais de saída do Protótipo P_3 para os gestos **zero**, **3** e **4**.

Sinal sensor	Gesto					
	zero		3		4	
	$\bar{X}$	σ	$\bar{X}$	σ	$\bar{X}$	σ
S_{f1}	456	4,30	422	5,97	479	17,27
S_{f2}	357	8,16	541	11,70	542	11,51
S_{f3}	230	1,61	402	21,62	393	25,92
S_{f4}	285	6,02	456	5,42	447	11,51
S_{f5}	61	6,28	83	2,35	126	5,33
A_{x1}	43	8,14	0	4,06	41	11,18
A_{y1}	5	10,08	-142	4,97	-119	6,20
A_{z1}	89	8,25	42	15,36	21	11,91
A_{x2}	127	7,94	-108	7,66	-103	10,88
A_{y2}	-112	7,04	-43	3,75	-37	6,60
A_{z2}	89	12,12	71	1,66	73	7,72
A_{x3}	0	2,72	-164	3,96	-159	7,34
A_{y3}	-162	3,26	0	9,64	0	5,50
A_{z3}	84	7,49	54	15,54	62	12,15
A_{x4}	2	7,30	-122	17,62	-153	9,49
A_{y4}	-163	5,76	3	6,11	0	16,90
A_{z4}	84	14,61	64	2,46	20	5,18
A_{x5}	-56	2,38	-149	4,12	-149	5,98
A_{y5}	43	12,07	20	4,50	24	16,83
A_{z5}	139	7,90	-63	8,96	-58	8,28
A_{x6}	68	6,25	-108	19,24	-116	13,98
A_{y6}	132	12,24	47	4,56	57	7,11
A_{z6}	80	5,80	119	0,45	96	3,26
A_{x7}	-32	6,37	-148	1,38	-160	8,00
A_{y7}	140	7,26	-47	4,96	-18	9,19
A_{z7}	91	18,61	-6	10,64	-6	14,98
A_{x8}	-18	16,31	-135	10,00	-152	15,16
A_{y8}	158	17,26	25	4,40	21	22,51
A_{z8}	-35	4,36	73	6,20	43	3,08
G_{x1}	-1	4,10	0	5,70	-2	18,41
G_{y1}	0	16,59	2	6,29	2	8,50
G_{z1}	-4	9,81	3	9,94	0	16,47
G_{x2}	-1	18,60	0	7,34	-3	17,43
G_{y2}	0	11,54	1	6,64	4	9,81
G_{z2}	0	4,72	2	13,12	-3	7,73
G_{x3}	-10	9,82	0	2,45	-5	15,03
G_{y3}	0	8,22	0	5,24	5	11,10
G_{z3}	0	18,16	1	7,59	-8	12,13
G_{x4}	0	11,06	0	6,65	0	13,30
G_{y4}	0	15,77	-25	7,10	0	23,46
G_{z4}	-1	17,19	4	4,71	-5	13,10
G_{x5}	5	12,00	15	3,57	0	14,64
G_{y5}	0	15,13	10	3,75	2	8,64
G_{z5}	1	9,28	-18	6,74	-9	17,03
G_{x6}	-1	19,13	-7	6,88	-13	11,26
G_{y6}	-2	13,66	-22	6,73	-1	8,85
G_{z6}	-4	15,84	2	3,68	-7	14,98
G_{x7}	-3	7,77	8	2,94	-3	11,18
G_{y7}	5	12,25	3	7,06	4	16,92
G_{z7}	2	18,17	-7	12,01	-14	10,82
G_{x8}	-7	5,82	9	12,08	-11	20,75
G_{y8}	15	9,88	2	3,56	0	11,19
G_{z8}	1	9,87	-8	2,87	-8	8,04

a representação da matriz de configuração $Q_{i,j}$, que neste caso representa o gesto **zero**, $Q(\text{zero})$ repetido 15 vezes. A Tabela 5.5(a) apresenta os sinais coletados e a

Tabela 5.4 - Sinais de saída do Protótipo P_3 para os gestos **i** e **j**.

(a) Gesto i			(b) Gesto j		
Sinal sensor	Repetição		Sinal sensor	Repetição	
	1 ^a	2 ^a		1 ^a	2 ^a
S_{f_1}	-19	-21	S_{f_1}	-21	-20
S_{f_2}	70	65	S_{f_2}	68	67
S_{f_3}	-3	12	S_{f_3}	-2	6
S_{f_4}	-19	-20	S_{f_4}	-22	-32
S_{f_5}	70	66	S_{f_5}	63	31
A_{x_1}	-2	11	A_{x_1}	-12	-21
A_{y_1}	-18	-20	A_{y_1}	-4	-1
A_{z_1}	71	66	A_{z_1}	60	44
A_{x_2}	-2	10	A_{x_2}	-29	-25
A_{y_2}	-18	-22	A_{y_2}	-13	-18
A_{z_2}	71	64	A_{z_2}	42	39
A_{x_3}	-2	10	A_{x_3}	-44	-69
A_{y_3}	30	27	A_{y_3}	27	20
A_{z_3}	18	32	A_{z_3}	17	24
A_{x_4}	52	44	A_{x_4}	56	57
A_{y_4}	31	27	A_{y_4}	28	-13
A_{z_4}	19	31	A_{z_4}	-23	-69
A_{x_5}	51	45	A_{x_5}	51	14
A_{y_5}	31	28	A_{y_5}	24	22
A_{z_5}	18	33	A_{z_5}	-40	-66
A_{x_6}	51	43	A_{x_6}	39	36
A_{y_6}	32	24	A_{y_6}	14	35
A_{z_6}	18	34	A_{z_6}	-51	-54
A_{x_7}	50	45	A_{x_7}	34	0
A_{y_7}	-7	-3	A_{y_7}	190	286
A_{z_7}	0	-3	A_{z_7}	12	-5
A_{x_8}	-7	-3	A_{x_8}	190	286
A_{y_8}	-7	-3	A_{y_8}	196	286
A_{z_8}	2	0	A_{z_8}	11	48
G_{x_1}	-7	-3	G_{x_1}	196	286
G_{y_1}	-6	-4	G_{y_1}	271	286
G_{z_1}	0	-1	G_{z_1}	44	164
G_{x_2}	-6	-4	G_{x_2}	271	286
G_{y_2}	-7	0	G_{y_2}	194	222
G_{z_2}	0	-2	G_{z_2}	66	282
G_{x_3}	-7	0	G_{x_3}	194	222
G_{y_3}	-2	0	G_{y_3}	-286	-261
G_{z_3}	0	-9	G_{z_3}	-31	-13
G_{x_4}	-2	0	G_{x_4}	-286	-261
G_{y_4}	-2	0	G_{y_4}	-252	-176
G_{z_4}	0	0	G_{z_4}	34	-74
G_{x_5}	-2	0	G_{x_5}	-252	-176
G_{y_5}	0	0	G_{y_5}	-180	-80
G_{z_5}	0	2	G_{z_5}	29	-159
G_{x_6}	0	0	G_{x_6}	-180	-80
G_{y_6}	-2	-1	G_{y_6}	-186	-60
G_{z_6}	0	3	G_{z_6}	-7	-260
G_{x_7}	-2	-1	G_{x_7}	-186	-60
G_{y_7}	5	4	G_{y_7}	5	4
G_{z_7}	2	-14	G_{z_7}	2	-14
G_{x_8}	-7	-11	G_{x_8}	-7	-11
G_{y_8}	15	0	G_{y_8}	15	0
G_{z_8}	1	-8	G_{z_8}	1	-8

Tabela 5.5(b) apresenta os dados normalizados.

Tabela 5.5 - Matriz de configuração $Q(\mathbf{zero})$ adquirida pelo Protótipo P_1 .

(a) Sinais de saída						(b) Dados normalizados					
Repetição	Sinais do Sensor					Repetição	Sinais do Sensor				
	S_{f_1}	S_{f_2}	S_{f_3}	S_{f_4}	S_{f_5}		S_{f_1}	S_{f_2}	S_{f_3}	S_{f_4}	S_{f_5}
1 ^a	448	352	232	280	59	1 ^a	1,000	0,506	-0,111	0,136	-1,000
2 ^a	453	350	226	277	56	2 ^a	1,000	0,481	-0,144	0,113	-1,000
3 ^a	453	355	228	283	61	3 ^a	1,000	0,500	-0,148	0,133	-1,000
4 ^a	452	352	228	282	60	4 ^a	1,000	0,490	-0,143	0,133	-1,000
5 ^a	452	357	229	282	58	5 ^a	1,000	0,518	-0,132	0,137	-1,000
6 ^a	456	357	230	280	57	6 ^a	1,000	0,504	-0,133	0,118	-1,000
7 ^a	455	356	231	281	59	7 ^a	1,000	0,500	-0,131	0,121	-1,000
8 ^a	455	356	228	280	55	8 ^a	1,000	0,505	-0,135	0,125	-1,000
9 ^a	457	358	230	282	59	9 ^a	1,000	0,503	-0,141	0,121	-1,000
10 ^a	458	360	231	283	60	10 ^a	1,000	0,508	-0,141	0,121	-1,000
11 ^a	456	361	231	283	62	11 ^a	1,000	0,518	-0,142	0,122	-1,000
12 ^a	458	359	228	281	58	12 ^a	1,000	0,505	-0,150	0,115	-1,000
13 ^a	458	361	229	283	63	13 ^a	1,000	0,509	-0,159	0,114	-1,000
14 ^a	459	359	226	284	62	14 ^a	1,000	0,496	-0,174	0,118	-1,000
15 ^a	460	362	228	281	58	15 ^a	1,000	0,512	-0,154	0,109	-1,000

5.3.1 Parâmetros iniciais da rede Perceptron múltiplas camadas

Após a normalização das matrizes $Q_{i,j}$, foram realizados os ensaios para escolha dos parâmetros da MLP, para isto, foi necessário apresentar os parâmetros iniciais para a RNA. Na rotina computacional, a matriz de configuração $Q_{i,j}$ foi dividida randomicamente em 70% para treinamento, 15% para validação e 15% para testes. Utilizou-se o método de validação cruzada e o erro máximo desejado como critério de parada do processo foi de 10^{-5} .

Após avaliações empíricas, foram aplicadas função de ativação tangente hiperbólica para camada intermediária e função de ativação linear para camada de saída. Estas funções fizeram a RNA convergir com maior eficiência (tempo $\times$ precisão) quando comparadas com outros arranjos de funções. Após a etapa de treinamento e validação, a topologia da MLP que resultar em melhor taxa de acertos é escolhida para treinar os pesos que serão utilizados na etapa de teste.

5.3.2 Taxas de aprendizagem

Observa-se que diferentes taxas de aprendizagem aplicadas entre a camada de entrada e as camadas intermediárias $\eta_{C_{EI}}$ e, as camadas intermediária e a camada de saída $\eta_{C_{IS}}$ geram influências significativas no desempenho da MLP. Isto justifica-se pelo erro obtido na camada de saída ser a comparação do valor da saída atual e o valor desejado para saída e o erro obtido na camada intermediária é o erro gerado a partir do produto da somatória dos pesos para última camada. Por consequência, a taxa de aprendizagem pode variar para diferentes aplicações.

Para validar esta afirmativa, testou-se os quatro protótipos desenvolvidos com diferentes taxas de aprendizagem $\eta_{C_{EI}}$ e $\eta_{C_{IS}}$ com 100 neurônios na camada intermediária. As médias de acertos da taxa de aprendizagem para 100 repetições do mesmo gesto são dispostas na Tabela 5.6. Após análise dos resultados obtidos, adota-se as taxas de aprendizados $\eta_{C_{EI}} = 10^{-5}$ e $\eta_{C_{IS}} = 10^{-3}$, por ser a opção que melhor se adequa aos protótipos.

Tabela 5.6 - Média de acertos da taxa de aprendizagem para 100 ensaios.

Protótipo	$\eta_{C_{EI}}$	$\eta_{C_{IS}}$	Média [%]	Eficiência [%]
P_1	10^{-3}	10^{-3}	23,6	26,36
	10^{-4}	10^{-4}	23,8	
	10^{-5}	10^{-5}	28,1	
	10^{-4}	10^{-3}	25,9	
	10^{-5}	10^{-3}	30,4	
P_2	10^{-3}	10^{-3}	60,3	74,34
	10^{-4}	10^{-4}	74,1	
	10^{-5}	10^{-5}	79,9	
	10^{-4}	10^{-3}	75,8	
	10^{-5}	10^{-3}	81,6	
P_3	10^{-3}	10^{-3}	79,4	85,40
	10^{-4}	10^{-4}	79,1	
	10^{-5}	10^{-5}	90,1	
	10^{-4}	10^{-3}	86,0	
	10^{-5}	10^{-3}	92,4	
P_4	10^{-3}	10^{-3}	80,1	86,52
	10^{-4}	10^{-4}	78,5	
	10^{-5}	10^{-5}	94,5	
	10^{-4}	10^{-3}	85,2	
	10^{-5}	10^{-3}	94,3	

Na Tabela 5.6 ainda é possível analisar a eficiência de cada protótipo utilizando média de acertos da taxa de aprendizagem. Para o cálculo desta eficiência utilizou-se a média dos valores contidos na Tabela 5.6 onde: i) o Protótipo P_1 obteve em média eficiência de 26,36%, ii) o Protótipo P_2 obteve em média eficiência de 74,34%, iii) o Protótipo P_3 obteve em média eficiência de 85,40% e v) o Protótipo P_4 obteve em média eficiência de 86,52%. De posse destes dados é possível realizar a avaliação entre os quatro protótipos construídos utilizando a taxa de aprendizado, onde o protótipo apenas com sensores de flexão (Protótipo P_1) obtém a menor eficiência e o protótipo apenas com MEMS (Protótipo P_4) obtém a melhor eficiência.

5.3.3 Topologia da rede Perceptron múltiplas camadas

Para verificar a quantidade de neurônios m_i necessários para camada intermediária, a MLP foi testada variando a quantidade de neurônios entre um e 500. Observou-se que na maioria das vezes quando $m_i \leq 80$ ocorria o efeito de *underfitting* e quando $m_i \geq 100$ ocorria o efeito de *overfitting*. Desta forma, realiza-se novos testes com

$82 \leq m_i \leq 100$. A Tabela 5.7 dispõe a média de acertos para 100 repetições do mesmo gesto utilizando os quatro protótipos.

Tabela 5.7 - Média de acertos para variações do número de neurônios nas camadas intermediárias com 100 repetições.

m_i	Média de Acerto [%]			
	P_1	P_2	P_3	P_4
82	49,6	69,2	89,8	89,1
86	50,0	57,4	83,2	87,1
91	20,2	89,6	95,8	96,0
95	62,0	82,6	88,8	95,7
100	30,4	81,6	92,4	94,3

Observa-se que o Protótipo P_1 obtém a melhor média de acerto de 62,00% com 95 neurônios nas camadas intermediárias, enquanto os Protótipo P_2 , Protótipo P_3 e Protótipo P_4 obtêm as melhores médias de acertos de 89,60%, 95,80% e 96,00%, respectivamente, com 91 neurônios nas camadas intermediárias. Verifica-se diferença de 33,80% entre o Protótipo P_1 e o Protótipo P_3 e 40,00% entre o Protótipo P_1 e o Protótipo P_4 . Portanto, assim como a eficiência calculada utilizando média de acertos da taxa de aprendizagem na Tabela 5.6, o Protótipo P_4 apresenta eficiência superior quando comparados aos demais protótipos. Com o intuito de avaliar a RNA e os protótipos com relação ao tamanho da base de dados, foram realizados novos ensaios com 500 repetições de mesmo gesto (500 vetores V_g). A Tabela 5.8 dispõe os resultados obtidos para esta análise.

Tabela 5.8 - Média de acertos para variações do número de neurônios nas camadas intermediárias com 500 repetições.

m_i	Média de Acerto [%]			
	P_1	P_2	P_3	P_4
82	50,4	69,3	91,2	88,5
86	48,7	63,9	85,6	86,7
91	34,6	91,2	96,1	94,9
95	67,8	81,4	88,9	96,8
100	30,2	82,2	90,7	91,8

Na Tabela 5.8, nos ensaios contendo 500 repetições de cada gesto, houve aumento de 5 vezes no tamanho da base de dados e a melhoria nas médias dos acertos foi de $\approx 1\%$, não compensando o esforço computacional. De qualquer forma, neste trabalho, a quantidade de repetições não foi padronizada em todos os estudos. Apenas neste estudo de caso e na validação foram utilizadas exatamente 500 repetições para análise do tamanho da base de dados e dos sinais dos protótipos.

Para o melhor desempenho do Protótipo P_1 a RNA deve ser treinada exaustivamente, além dele apresentar desvantagens quando os gestos são dinâmicos. O Protótipo P_4 foi melhor avaliado tanto pelo desempenho da RNA quanto pelo custo, pois possui menor quantidade de sensores. Pode-se abstrair que o desempenho da RNA está ligada ao modelo do protótipo utilizado. Se o protótipo consegue disponibilizar mais sinais e se estes sinais são representações precisas dos gestos, a RNA identificará os gestos com menor esforço computacional.

A topologia para teste da rede MLP contém 95 neurônios na camada intermediária, taxas de aprendizado $\eta_{CEI} = 10^{-5}$ e $\eta_{CIS} = 10^{-3}$. A base de dados contém 500 repetições de mesmo gesto (500 linhas na matriz de configuração) e foi utilizado somente o Protótipo P_4 .

5.4 Validação dos resultados

Com o intuito de validar o Protótipo P_4 que obteve o melhor resultado e a topologia da MLP, selecionou-se seis gestos entre os 36 gestos treinados. Na escolha dos gestos foram levados em consideração as semelhanças entre as configurações de mão e as diferenças de orientação e de movimento. Os gestos selecionados foram: **a**, **e**, **i**, **j**, **x** e **5**. A Figura 5.8 apresenta os gestos e a Tabela 5.9 dispõe as médias de acertos dos gestos utilizando a MLP com a topologia proposta.




Figura 5.8 - Gestos: (a) letra **a**, (b) letra **e**, (c) letra **i**, (d) letra **j**, (e) letra **x** e (f) número **5**.

Tabela 5.9 - Média de acertos do Protótipo P_4 para os gestos **a**, **e**, **i**, **j**, **x** e **5**.

Gesto	Média de Acerto [%]
a	100
e	100
i	100
j	96,5
x	97,1
5	98,4

A partir da análise da Tabela 5.9 observou-se que os gestos estáticos apresentam

média de acerto acima de 98%, enquanto os gestos dinâmicos apresentam média de acerto de aproximadamente 96%. A Figura 5.9 apresenta a disposição dos valores obtidos nos oito sensores conectados ao Protótipo P_4 para os gestos da Tabela 5.9. Na Figura 5.9 o eixo das abcissas representa a sequência de sensores de $A_{x_1}, A_{y_1}, A_{z_1}, \dots, A_{x_8}, A_{y_8}, A_{z_8}$ e de $G_{x_1}, G_{y_1}, G_{z_1}, \dots, G_{x_8}, G_{y_8}, G_{z_8}$, formando 48 pontos e o eixo das ordenadas representa os valores obtidos em cada sensor. Portanto, os sinais de um a 24 são relativos aos sensores acelerômetros e os sinais de 25 a 48 são relativos aos sensores giroscópios.

Na Figura 5.9(a) os gestos **a** e **e** são gestos estáticos e seus sinais são semelhantes, na Figura 5.9(b) e Figura 5.9(c), os gestos **j** e **x** são gestos dinâmicos e os sinais medidos são diferentes dos sinais medidos dos gestos **i** e **5**, a partir do sensor oito, ponto 24 no eixo das abcissas. A Figura 5.10 apresenta o mapeamento dos sinais medidos do gesto **a** repetido 30 vezes.

Para verificar a eficiência do Protótipo P_4 e da MLP com relação as palavras, foram escolhidas cinco palavras da língua brasileira: **telefone**, **gato**, **leão**, **pipa** e **amarelo**. Estas palavras são apresentadas na forma de gestos na Figura 5.11.

Os valores das médias dos acertos obtidos para as palavras são dispostos na Tabela 5.10. Na Figura 5.11 observa-se que a palavra **telefone** é estática e por este motivo apresenta 100% de acerto. Nas demais palavras existem movimentos, ocasionando média de acerto entre 96,30% e 98,8%.

Tabela 5.10 - Média de acertos do Protótipo P_4 para as palavras.

Gesto	Média de Acerto [%]
telefone	100
gato	97,5
leão	98,8
pipa	98,7
amarelo	96,3

A topologia da MLP em conjunto com o Protótipo P_4 é capaz de oferecer eficiência acima de 96% para novos gestos treinados. A partir dos sinais coletados do Protótipo P_4 , a rede MLP foi capaz de reconhecer gestos estáticos e dinâmicos, referentes aos caracteres e palavras da Libras.




Figura 5.9 - Relação dos valores obtidos nos sensores para gestos semelhantes: (a) gestos **a** e **e**, (b) gestos **i** e **j** e (c) gestos **5** e **x**.

5.5 Gestos dinâmico com mais de uma coleta no tempo

Para capturar a dinâmica dos gestos, levando em conta os movimentos, pode-se coletar os dados no tempo, como exemplificado na Figura 4.10. Os sinais produzidos pelos sensores podem ser coletados em três tempos distintos: i) t_0 que é o tempo para gerar o primeiro conjunto de sinais, ii) t_{A_g} que é o tempo de aquisição dos MEMS, neste caso $t_{A_g} = 2,5 \cdot 10^{-3} s$ e iii) t_δ que é o tempo de coleta quando os sinais coletados dos giroscópios estabilizaram-se.




Figura 5.10 - Sinais obtidos pela repetição do gesto **a** por 30 vezes.




Figura 5.11 - Gestos: (a) **telefone**, (b) **gato**, (c) **leão**, (d) **pipa** e (e) **amarelo**.

A Tabela 5.11 apresenta os dados coletados pelo Protótipo P_4 quando é produzido o gesto que identifica a palavra **leão**. Observa-se que as variações nos valores dos sinais do giroscópio são maiores em t_0 e t_{A_g} , sendo relevantes para verificar a configuração e orientação inicial da mão. A coleta em t_δ independe do tempo gasto na produção do gesto e é necessária para verificar a última configuração e orientação da mão.

A Tabela 5.12 dispõe as médias $\bar{X}$ e o desvio padrão σ dos sinais obtidos nos sensores para a produção do gesto **leão** dispostos na Tabela 5.11. A metodologia desenvolvida não limita tempo máximo para produção do gesto. A metodologia desenvolvida não limita tempo máximo para produção do gesto. Isto facilita a utilização do protótipo pelo usuário, pois cada usuário terá seu tempo de produção para o mesmo gesto. O exemplo apresentado foi para coleta de sinais em três tempos distintos, no entanto, esta metodologia pode ser aplicada para qualquer intervalo de tempo, bastando definir a quantidade de intervalos e os tempos entre uma coleta e outra. A Figura 5.12

Tabela 5.11 - Sinais coletados no tempo com o Protótipo P_4 .

(a) Acelerômetros.				(b) Giroscópios.			
Sinal sensor	Tempo de coleta			Sinal sensor	Tempo de coleta		
	t_0	t_{A_g}	t_δ		t_0	t_{A_g}	t_δ
A_{x1}	-14	22	-3	G_{x1}	286	-147	-16
A_{y1}	71	-53	-18	G_{y1}	-35	77	15
A_{z1}	-11	-26	-71	G_{y1}	286	-147	-16
A_{x2}	-9	-21	14	G_{x2}	286	-41	-11
A_{y2}	25	-8	5	G_{y2}	136	58	23
A_{z2}	62	-67	-75	G_{z2}	286	-41	-11
A_{x3}	22	-3	16	G_{x3}	286	-20	-7
A_{y3}	-53	-18	4	G_{y3}	121	28	16
A_{z3}	-26	-71	-72	G_{z3}	286	-20	-7
A_{x4}	10	6	16	G_{x4}	246	-24	-4
A_{y4}	-66	-19	2	G_{y4}	30	-13	4
A_{z4}	-20	-69	-73	G_{z4}	246	-24	-4
A_{x5}	2	32	14	G_{x5}	-286	-88	-13
A_{y5}	70	-37	-37	G_{y5}	-72	53	3
A_{z5}	19	35	49	G_{z5}	-286	-88	-13
A_{x6}	18	20	21	G_{x6}	-157	-55	-14
A_{y6}	-56	-38	-28	G_{y6}	-66	35	0
A_{z6}	27	44	53	G_{z6}	-157	-55	-14
A_{x7}	32	14	20	G_{x7}	4	-4	-15
A_{y7}	-37	-37	-30	G_{y7}	23	33	3
A_{z7}	35	49	51	G_{z7}	4	-4	-15
A_{x8}	28	15	20	G_{x8}	31	-58	-8
A_{y8}	-31	-28	-30	G_{y8}	25	48	2
A_{z8}	45	57	52	G_{z8}	31	-58	-8

apresenta fluxograma para coleta de gestos dinâmicos.

5.6 Comentários

No desenvolvimento do trabalho, foram observados problemas com relação a posição do sensor de flexão. Este sensor é frágil e seus condutores partem com facilidade. Desta forma, estes sensores foram alocados o mais distante possível das articulações da mão. No entanto, ficando longe das articulações, ele não captura os movimentos dos dedos corretamente. Para a conexão dos sensores de flexão com a luva, utilizou-se fita dupla face, na tentativa de evitar a movimentação do sensor.

Os módulos GY-521 possuem tamanho maior que o desejado para luva de tamanho médio e velocidade de aquisição de até $400Hz$. A taxa de amostragem limitou-se a velocidade de aquisição dividida pela quantidade de módulos GY-521 que foi utilizada no protótipo. Sugere-se confeccionar novos encapsulamentos com mesma funcionalidade, com tamanho menor e com maior velocidade de aquisição. Para que usuários com diferentes tamanhos de mão possam usar os protótipos, faz-se necessário a utilização de material mais flexível na construção das luvas ou a produção de protótipo que não utilize a luva, somente os sensores.

Tabela 5.12 - Média e desvio padrão dos sinais obtidos no Protótipo P_4 para o gesto **leão**.

(a) Acelerômetros.							(b) Giroscópios.						
Sinal	Tempo de coleta						Sinal	Tempo de coleta					
sensor	t_0		t_{A_g}		t_δ		sensor	t_0		t_{A_g}		t_δ	
	$\bar{X}$	σ	$\bar{X}$	σ	$\bar{X}$	σ		$\bar{X}$	σ	$\bar{X}$	σ	$\bar{X}$	σ
A_{x_1}	-15	1,50	30	10,79	8	14,40	G_{x_1}	288	2,41	-140	8,59	-5	14,24
A_{y_1}	64	9,58	-62	11,19	-5	16,84	G_{y_1}	-43	10,96	70	9,50	28	17,26
A_{z_1}	-11	0,14	-27	1,65	-53	24,02	G_{y_1}	289	3,72	-149	3,22	3	24,74
A_{x_2}	4	16,95	-22	1,59	14	0,18	G_{x_2}	302	20,79	-42	1,85	-11	0,14
A_{y_2}	11	18,06	-26	23,74	-12	22,26	G_{y_2}	123	16,61	40	22,88	6	22,02
A_{z_2}	75	16,56	-78	14,00	-81	7,54	G_{z_2}	301	19,47	-52	13,66	-16	6,71
A_{x_3}	2	25,97	-5	2,67	20	5,46	G_{x_3}	269	22,54	-22	2,89	-3	5,16
A_{y_3}	-38	19,01	-18	0,23	10	7,93	G_{y_3}	137	21,27	28	0,36	22	8,09
A_{z_3}	-8	23,30	-82	14,05	-67	6,94	G_{z_3}	307	27,35	-30	13,39	-1	7,79
A_{x_4}	25	19,83	24	23,71	29	17,28	G_{x_4}	264	22,89	-6	23,32	9	17,02
A_{y_4}	-69	3,48	-5	18,14	6	5,28	G_{y_4}	28	2,24	1	18,21	8	5,30
A_{z_4}	0	26,00	-58	14,86	-80	8,83	G_{z_4}	269	29,46	-12	15,44	-10	7,93
A_{x_5}	15	17,10	45	17,49	-4	23,45	G_{x_5}	-276	13,35	-76	15,93	-31	23,80
A_{y_5}	57	17,47	-39	3,11	-36	0,83	G_{y_5}	-87	19,32	52	1,94	4	1,35
A_{z_5}	19	0,25	28	8,74	60	13,77	G_{z_5}	-289	3,72	-96	10,34	-3	12,96
A_{x_6}	26	10,74	9	14,18	14	8,92	G_{x_6}	-150	8,46	-67	15,16	-21	9,37
A_{y_6}	-76	25,68	-19	24,45	-36	10,87	G_{y_6}	-86	25,81	55	25,40	-8	10,50
A_{z_6}	36	12,17	53	11,08	53	0,62	G_{z_6}	-149	9,78	-47	9,79	-15	1,50
A_{x_7}	14	23,22	31	22,50	8	15,50	G_{x_7}	-14	23,58	13	22,27	-27	15,95
A_{y_7}	-51	17,55	-30	8,71	-38	10,89	G_{y_7}	10	16,77	40	9,62	-5	10,47
A_{z_7}	52	21,46	45	4,62	40	13,78	G_{z_7}	20	21,06	-8	5,30	-26	14,64
A_{x_8}	40	16,12	-4	24,75	3	22,06	G_{x_8}	43	16,16	-78	25,70	-25	22,43
A_{y_8}	-45	18,79	-25	3,58	-31	1,70	G_{y_8}	11	18,06	52	4,56	1	1,29
A_{z_8}	48	4,52	38	24,21	46	7,20	G_{z_8}	34	4,34	-78	25,70	-14	7,98

Os sensores acelerômetro e giroscópio são sensíveis a pequenas variações na posição, produzindo ruídos. Neste trabalho, os ruídos foram tratados apenas nos filtros digitais que existem no microcontrolador (INVENSENSE, 2016). Para melhorar desempenho do conjunto protótipo/RNA, quando coletando vários sinais no tempo, pode-se projetar reconhecimento de padrões em cascata. Os protótipos propostos utilizam cabeamento para enviar os dados para o computador. É possível implementar a comunicação sem fio para melhorar o movimento das mãos na produção dos gestos.

O Protótipo P_1 é dispositivo comercial e são utilizados sensores de flexão, com tecnologia de flexores de fibra óptica. Cada protótipo desenvolvido neste trabalho foi avaliado pela quantidade de sensores. Como cada sensor pode produzir tipos de sinais diferentes, tem-se: i) o Protótipo P_1 com cinco sensores e cinco sinais, ii) o Protótipo P_2 com sete sensores e dezessete sinais, iii) o Protótipo P_3 com treze sensores e 53 sinais e iv) o Protótipo P_4 com oito sensores e 48 sinais. Os sensores de flexão custam em média \$33,00 e os MEMS custam em média \$6,00. Sem levar em consideração a luva e considerando apenas os sensores, o Protótipo P_1 fica aproximadamente 300% mais oneroso que o Protótipo P_4 , que obteve a melhor




Figura 5.12 - Fluxograma para coleta de gestos dinâmicos.

eficiência.

CAPÍTULO 6

CONCLUSÃO

Durante a execução deste trabalho, buscou-se projetar, desenvolver e analisar o desempenho de protótipos com abordagem sensorial e tecnologia baseada em redes neurais artificiais, do tipo Perceptron múltiplas camadas. Nesta busca, foram projetados dispositivos para reconhecer configuração, orientação e movimento das mãos, utilizadas na língua brasileira de sinais, e traduzir para a linguagem escrita. O trabalho surgiu da problemática do grupo de pesquisa do Instituto Politécnico do Porto (IPPorto/Portugal) que, ao desenvolver sistema bidirecional para língua de sinais, utilizou luvas comerciais para reconhecer gestos estáticos. O dispositivo utilizado pelo grupo de pesquisa possui alto custo e sofrem rupturas devida a utilização contínua. O trabalho se destaca por desenvolver dispositivo para reconhecer gestos estáticos e dinâmicos, com arranjo de sensores de baixo custo e precisão.

Para obter precisão na captura dos sinais, a disposição dos sensores deve verificar o comprimento total dos dedos e da mão, evitando o rompimento dos contatos dos sensores e do microcontrolador. Além disto, o tamanho dos sensores deve ser compatível ao tamanho da mão do usuário. Deve-se projetar e desenvolver dispositivos com materiais leves e flexíveis para construção das luvas ou que não utilize luvas, somente acoplando os sensores a mão.

Para o desenvolvimento do trabalho, construiu-se a base de dados dos gestos propostos para reconhecimento, análise, qualificação e quantificação dos resultados dos quatro protótipos propostos, a etapa de validação foi dividida em duas partes: i) validação de protótipos e ii) validação da rotina computacional e RNA. A validação do protótipo é obtida por sua eficácia e eficiência, enquanto a validação da rotina computacional e RNA analisa os resultados obtidos para as diferentes topologias assumidas. Por fim, o Protótipo P_4 obteve os melhores resultados de avaliação, reconhecendo gestos estáticos, dinâmicos e novos gestos utilizando a mesma topologia da MLP treinada.

Ao validar os protótipos, os sinais coletados e o posicionamento dos sensores nos protótipos apresentaram eficácia e eficiência de 86,52% utilizando 100 neurônios na camada intermediária. Ao validar a topologia da MLP, os protótipos apresentaram as melhores taxas de acerto: i) Protótipo P_1 com 67,8%, ii) Protótipo P_2 com 91,2%, iii) Protótipo P_3 com 96,1% e iv) Protótipo P_4 com 96,8%.

Portanto, conclui-se que a utilização de sensores do tipo acelerômetro e giroscópio é promissor e viável para o presente projeto contendo vantagem pela ausência de interferências externas. O protótipo desenvolvido e validado apresenta resultados relevantes nas tecnologias para comunicação em língua brasileira de sinais. Além disto, destaca-se por se destinar a inclusão social, auxiliar e aprimorar o ensino da língua de sinais.

6.1 Contribuições do Trabalho

As contribuições podem ser assim descritas:

- Desenvolvimento de protótipo capaz de reconhecer gesticulações estáticas e dinâmicas e reconhecer língua de sinais.
- Redução de custos para dispositivos que reconhecem gestos.
- Auxiliar na inclusão social e comunicação assertiva entre surdos e ouvintes, entre língua oral e língua de sinais.
- Desenvolvimento do leiaute da Luva do Protótipo P_4 em conjunto com a Empresa NC Neoprene.

Artigos publicados em anais de eventos nacionais e internacionais:

- SILVA, B. C. R., FURRIEL, G. P., CALIXTO, W. P., BULHOES, J. S. Methodology and comparison of devices for recognition of sign language characters. In Electric Power Engineering (EPE), 18th International Scientific Conference on (pp. 1-6). IEEE. Czech Republic. 2017.
- SILVA, B. C. R., FURRIEL, G. P., CALIXTO, W. P., BULHOES, J. S. Devices analysis and artificial neural network parameters for sign language recognition. Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON). Pucon - Chile. 2017.
- LINO, A. L. S. ; ROCHA, D. P. C. ; SILVA, B. C. R. ; CALIXTO, W. P. ; FURRIEL, G. P. . Performance of haar and LBP features in cascade classifiers to whiteflies detection and counting. In: Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON). Pucon - Chile. 2017.

- BULHOES, JUNIO SANTOS ; ASSIS, A. O. ; MARTINS, C. L. ; FURRIEL, G. P. ; SILVA, B. C. R. ; RODRIGUES, L. ; REIS, M. R. C. ; CALHEIROS, D. F. ; OLIVEIRA, M. D. ; CALIXTO, W. P. Gap filling in time series: A new methodology applying spectral analysis and system identification. In: Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON). Pucon - Chile. 2017.
- SILVA, L. F. A. ; SILVA, M. C. ; ALVES, A. J. ; REIS, M. R. C. ; BULHOES, J. S. ; SILVA, B. C. R. ; COSTA, R. E. ; ALEIXO, E. L. ; GOMES, V. M. ; CALIXTO, W. P. . Socioeconomic, scientific and technological indicators as parameters for prediction model. In: Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON). Pucon - Chile. 2017.
- SILVA, B. C. R., FURRIEL, G. P., CALIXTO, W. P., REIS, M. R. C. Desenvolvimento de luva para reconhecimento de caracteres em linguagem de sinais - 14^a Congresso de Pesquisa, Ensino e Extensão (Conpeex) - Universidade Federal de Goiás. 2016.

Artigo aceito para publicação em Periódico Internacional:

- SILVA, B. C. R., FURRIEL, G. P., CALIXTO, W. P., BULHOES, J. S. Methodology and comparison of devices for recognition of sign language characters. In Advances in Science, Technology and Engineering Systems Journal (ASTESJ).

Patentes e Registros:

- SILVA, B. C. R.; FURRIEL, G. P.; REIS, M. R. C.; CALIXTO, W. P.. Dispositivo Eletrônico Tradutor de Gestos para a Língua de Sinais 2018, Brasil. Patente: Privilégio de Inovação.

6.2 Sugestões para Trabalhos Futuros

- Comparar e unir respostas referentes a abordagens sensoriais do trabalho proposto com abordagens visuais.
- Desenvolver tradutor bidirecional da língua de sinais.

- Reconhecimento de frases completas na língua de sinais.
- Avaliar outros algoritmos para reconhecimento de padrões.
- Criar matriz de confusão referente ao sistema de reconhecimento.
- Generalização para outras línguas de sinais.
- Tradução da língua de sinais para a forma escrita da própria língua de sinais.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDEL-HAMID, O.; MOHAMED, A.-r.; JIANG, H.; DENG, L.; PENN, G.; YU, D. Convolutional neural networks for speech recognition. **IEEE/ACM Transactions on audio, speech, and language processing**, IEEE, v. 22, n. 10, p. 1533–1545, 2014. [53](#)

AHMED, A. M.; ALEZ, R. A.; TAHA, M.; THARWAT, G. Automatic translation of arabic sign to arabic text (atasat) system. **Computer Science & Information Technology**, p. 109, 2016. [32](#)

ALMEIDA, S. G. M. Extração de características em reconhecimento de parâmetros fonológicos da língua brasileira de sinais utilizando sensores rgb-d. UFMG, 2014. [29](#)

ANDRADE, L. N. Redes neurais artificiais aplicadas na identificação automação de áreas cafeeiras em imagens de satélite. UFMG, 2011. [44](#), [45](#), [48](#)

ARCE, A. I. C.; SILVA, A. C. de S.; SCHALCH, F. J.; TITTO, E. A. L.; COSTA, E. J. X. Desenvolvimento de um sistema microcontrolado de monitoração da temperatura e avaliação do implante do elemento sensor digital em bovinos. **Ciência Animal Brasileira**, v. 8, n. 3, p. 417–424, 2007. [42](#)

BALBINOT, A.; BRUSAMARELLO, V. J. **Instrumentação E Fundamentos de Medidas. Volume 2** . [S.l.: s.n.], 2000. [37](#)

BARCLAY, D.; SILVER, G.; VERSTEEGH, J.; LANOIL, B. **Sensor glove**. [S.l.]: Google Patents, 2011. US Patent 7,862,522. [37](#)

BARSHAN, B.; DURRANT-WHYTE, H. F. Inertial navigation systems for mobile robots. **IEEE Transactions on Robotics and Automation**, IEEE, v. 11, n. 3, p. 328–342, 1995. [40](#)

BEBIS, G.; GEORGIOPOULOS, M. Feed-forward neural networks. **IEEE Potentials**, IEEE, v. 13, n. 4, p. 27–31, 1994. [48](#), [50](#)

BEEBY, S. **MEMS mechanical sensors**. [S.l.]: Artech House, 2004. [38](#)

BORGHETTI, M.; SARDINI, E.; SERPELLONI, M. Sensorized glove for measuring hand finger flexion for rehabilitation purposes. **IEEE Transactions on Instrumentation and Measurement**, IEEE, v. 62, n. 12, p. 3308–3314, 2013. [23](#)

BRASIL, C. Decreto 5.626, de 22 de dezembro de 2005. **Diário Oficial da República Federativa do Brasil, Poder Executivo, Brasília, DF**, v. 23, 2005. 25

BUI, T.; NGUYEN, L. T. Recognizing postures in vietnamese sign language with mems accelerometers. **IEEE sensors journal**, IEEE, v. 7, n. 5/6, p. 707, 2007. 22, 32

CHEVALLIER, P. Aquisição e processamento de dados. **TUCCI, CEM Hidrologia: ciência e aplicação. Porto Alegre: Ed. Universidade/UFRGS**, p. 483–525, 2001. 36, 37

COELHO, O.; CABRAL, E.; GOMES, M. do C. Formação de surdos: ao encontro da legitimidade perdida. 2004. 26

COSTA, A. d. O. M. C. **Reconhecimento de língua gestual**. Tese (Doutorado) — Instituto Superior de Engenharia de Lisboa, 2014. 26

CUNHA, F. L.; FRANCA, J. E.; ORTOLAN, R. L.; CLIQUET, A. J. O uso de redes neurais artificiais para o reconhecimento de padrões em uma prótese mioelétrica de mão. In: **VIII Congresso Brasileiro de Redes Neurais**. [S.l.: s.n.], 2007. 35, 36, 48

CYBENKO, G.; ALLEN, T.; POLITO, J. Practical parallel union-find algorithms for transitive closure and clustering. **International journal of parallel programming**, Springer, v. 17, n. 5, p. 403–423, 1988. 48

DAS, P.; DE, R.; PAUL, S.; CHOWDHURY, M.; NEOGI, B. Analytical study and overview on glove based indian sign language interpretation technique. **IET**, 2015. 23, 32

DEMUTH, H. B.; BEALE, M. H.; JESS, O. D.; HAGAN, M. T. **Neural network design**. [S.l.]: Martin Hagan, 2014. 51, 53

DESHMUKH, A. V. **Microcontrollers: theory and applications**. [S.l.]: Tata McGraw-Hill Education, 2005. 41

FANG, G.; GAO, W.; ZHAO, D. Large vocabulary sign language recognition based on hierarchical decision trees. In: **ACM. Proceedings of the 5th international conference on Multimodal interfaces**. [S.l.], 2003. p. 125–131. 22

FARRELL, J. **Aided navigation: GPS with high rate sensors**. [S.l.]: McGraw-Hill, Inc., 2008. 40, 41

- FERNANDES, C. C.; ROMEIRO, C. de A. A contribuição da datilologia como estratégia metodológica no processo de alfabetização. **Revista diálogos**, v. 4, n. 1, p. 170–185, 2017. [31](#)
- FERREIRA, A. L.; WECK, J.; SILVA, J. da; SOUSA, M. do Vale de; SANTOS, P. de A. Aprendendo libras: módulo 2. **Natal: EDUFRN**, 2011. [21](#)
- FERREIRA-BRITO, L. **Por uma gramática Línguas de Sinais**. [S.l.]: Tempo Brasileiro, 2010. [27](#)
- FORHAN, N. A. E.; SENNA, J. R. S. Giroscopios mems. **urlib. net/sid. inpe. br/mtc-m19**, v. 80, p. 01–25, 2010. [39](#)
- GALLO, M. A.; HANCOCK, W. S.; SILVA, F. S. C. da; CARNEIRO, M. R. de F.; MELO, A. C. V. de. **Comunicação entre computadores e tecnologias de rede**. [S.l.]: Pioneira Thomson Learning, 2003. [42](#)
- GARDNER, M. W.; DORLING, S. Artificial neural networks (the multilayer perceptron) a review of applications in the atmospheric sciences. **Atmospheric environment**, Elsevier, v. 32, n. 14-15, p. 2627–2636, 1998. [51](#), [52](#)
- GRITSENKO, A.; EIROLA, E.; SCHUPP, D.; RATNER, E.; LENDASSE, A. Probabilistic methods for multiclass classification problems. In: **Proceedings of ELM-2015 Volume 2**. [S.l.]: Springer, 2016. p. 385–397. [53](#)
- HAMPSHIRE, J. B.; PEARLMUTTER, B. Equivalence proofs for multi-layer perceptron classifiers and the bayesian discriminant function. In: **Connectionist Models**. [S.l.]: Elsevier, 1991. p. 159–172. [55](#)
- HAYKIN, S. S.; HAYKIN, S. S.; HAYKIN, S. S.; HAYKIN, S. S. **Neural networks and learning machines**. [S.l.]: Pearson Upper Saddle River, NJ, USA:, 2009. [43](#), [47](#), [48](#), [51](#)
- HICKOK, G.; BELLUGI, U.; KLIMA, E. A língua de sinais no cérebro. **Rev Scientific Am Bras [sd]**, p. 50–7, 2004. [29](#)
- INVENSENSE, I. M. **MPU-6000 and MPU-6050 Register Map and Description**. [S.l.: s.n.], 2016. [40](#), [73](#), [88](#)
- JAKOBSON, R. **Linguística e comunicação**. [S.l.]: Editora Cultrix, 2008. [25](#)
- KHASHEI, M.; BIJARI, M. An artificial neural network (p, d, q) model for timeseries forecasting. **Expert Systems with applications**, Elsevier, v. 37, n. 1, p. 479–489, 2010. [44](#)

KNIGHT, J. F.; BRISTOW, H. W.; ANASTOPOULOU, S.; BABER, C.; SCHWIRTZ, A.; ARVANITIS, T. N. Uses of accelerometer data collected from a wearable system. **Personal and Ubiquitous Computing**, Springer, v. 11, n. 2, p. 117–132, 2007. [38](#)

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: **Advances in neural information processing systems**. [S.l.: s.n.], 2012. p. 1097–1105. [52](#)

KULIK, S. Neural network model of artificial intelligence for handwriting recognition. **Journal of Theoretical & Applied Information Technology**, v. 73, n. 2, 2015. [53](#)

KURODA, T.; TABATA, Y.; GOTO, A.; IKUTA, H.; MURAKAMI, M. et al. Consumer price data-glove for sign language recognition. In: **Proc. of 5th Intl Conf. Disability, Virtual Reality Assoc. Tech., Oxford, UK**. [S.l.: s.n.], 2004. p. 253–258. [22](#), [23](#)

LACERDA, C. B. de. Um pouco da história das diferentes abordagens na educação dos surdos. **Cadernos Cedes**, v. 19, p. 68–citation_lastpage, 1998. [21](#), [26](#)

LEI, L.; DASHUN, Q. Design of data-glove and chinese sign language recognition system based on arm9. In: IEEE. **Electronic Measurement & Instruments (ICEMI), 2015 12th IEEE International Conference on**. [S.l.], 2015. v. 3, p. 1130–1134. [23](#)

LI, Y.; CHEN, X.; TIAN, J.; ZHANG, X.; WANG, K.; YANG, J. Automatic recognition of sign language subwords based on portable accelerometer and emg sensors. In: ACM. **International Conference on Multimodal Interfaces and the Workshop on Machine Learning for Multimodal Interaction**. [S.l.], 2010. p. 17. [22](#)

LIBONATI, P. A. O.; OLIVEIRA, A. **Sistema de aquisição de dados para laboratórios**. Tese (Doutorado) — Universidade Federal da Bahia, 2002. [36](#)

LIMA, J. J.; MARTINS, M. R.; OKIDA, S.; JR, S. L. S.; SCHLEDER, J. C. Dispositivo para análise dinâmica da marcha humana utilizando sensores inerciais mems. **Revista de Engenharia e Tecnologia**, v. 5, n. 3, p. Páginas–122, 2013. [39](#)

LODI, A. C. B. Educação bilíngue para surdos e inclusão segundo a política nacional de educação especial e o decreto nº 5.626/05. **Educação e Pesquisa**, SciELO Brasil, v. 39, n. 1, p. 49–63, 2013. [26](#)

MAENAKA, K. Mems inertial sensors and their applications. In: IEEE. **Networked Sensing Systems, 2008. INSS 2008. 5th International Conference on**. [S.l.], 2008. p. 71–73. [38](#), [39](#)

MASUTTI, M. L.; SANTOS, S. A. d. Intérpretes de língua de sinais: uma política em construção. **Quadros RM, organizador. Estudos surdos III. Petrópolis: Arara Azul**, p. 148–67, 2008. [27](#)

MATTELART, A.; MATTELART, M. **História das teorias da comunicação**. [S.l.]: Edições Loyola, 2011. [25](#)

MAYAGOITIA, R. E.; NENE, A. V.; VELTINK, P. H. Accelerometer and rate gyroscope measurement of kinematics: an inexpensive alternative to optical motion analysis systems. **Journal of biomechanics**, Elsevier, v. 35, n. 4, p. 537–542, 2002. [38](#)

MENEZES, D. B. et al. Mitos sobre a língua de sinais e o surdo: percepção de professores da universidade federal de goiás. **Relatório das atividades realizadas para a Prática como Componente Curricular. Goiânia**, 2009. [29](#)

MONTEIRO, S. S.; VIANA, D. S.; OLIVEIRA, T. M. de; GONÇALVES, A. R. C.; MORENO, E. D. Implementação do ip core i2c bus controller. **XV Simpósio em Sistemas Computacionais de Alto Desempenho**, 2014. [42](#)

MORAES, G.; ARAUJO, G. M. D. **Elementos do Sistema de Gestão de SMSQRS**. [S.l.]: Gerenciamento Verde Editora, 2010. [25](#)

NASCIMENTO, L.; FREITAS, M.; JÚNIOR, J. M.; JR, S. S. **METODOLOGIA DE CARACTERIZAÇÃO DE UM SENSOR DE FLEXÃO**. [S.l.: s.n.], 2017. [37](#)

NEXPERIA. **Datasheet 74HC/HCT138 3-to-8 line decoder/demultiplexer**. 2015. [73](#)

NORGAARD, M.; RAVN, O.; POULSEN, N.; HANSEN, L. **Neural networks for modelling and control of dynamic systems: a practitioners handbook. Advanced textbooks in control and signal processing**. [S.l.]: Springer, Berlin, 2000. [45](#)

NOVAES, E. C. Surdos: educação, direito e cidadania. **Rio de Janeiro: Wak Ed**, 2010. 26

OKADA, R. T. Avaliação experimental de medidas de aceleração. Universidade Estadual Paulista (UNESP), 2012. 38

ORDONEZ, E. D. M. **Projeto, desempenho e aplicações de sistemas digitais em circuitos programáveis (FPGAs)**. [S.l.]: Cesar Giacomini Penteado, 2003. 42

PATHAK, V.; MONGIA, S.; CHITRANSHI, G. A framework for hand gesture recognition based on fusion of flex, contact and accelerometer sensor. In: IEEE. **Image Information Processing (ICIIP), 2015 Third International Conference on**. [S.l.], 2015. p. 312–319. 23

PHI, L. T.; NGUYEN, H. D.; BUI, T. Q.; VU, T. T. A glove-based gesture recognition system for vietnamese sign language. In: IEEE. **Control, Automation and Systems (ICCAS), 2015 15th International Conference on**. [S.l.], 2015. p. 1555–1559. 32

POKER, R. B. Abordagens de ensino na educação da pessoa com surdez. **LIBRAS à Distância. UNESP.**, v. 15, n. 09, 2011. 26, 27

PRAVEEN, N.; KARANTH, N.; MEGHA, M. Sign language interpreter using a smart glove. In: IEEE. **Advances in Electronics, Computers and Communications (ICAIECC), 2014 International Conference on**. [S.l.], 2014. p. 1–5. 22

PRECHELT, L. Automatic early stopping using cross validation: quantifying the criteria. **Neural Networks**, Elsevier, v. 11, n. 4, p. 761–767, 1998. 53

QUADROS, R. d.; PERLIN, G. **Estudos surdos 2**. [S.l.: s.n.], 2007. 26

QUADROS, R. M. **Educação de surdos: a aquisição da linguagem**. [S.l.]: Artmed Editora, 2009. 26

QUADROS, R. M.; CRUZ, C. R. **Língua de sinais**. [S.l.]: Artmed Editora, 2009. 21, 29, 30, 32

QUADROS, R. M. de; KARNOPP, L. B. **Língua de sinais brasileira: estudos linguísticos**. [S.l.]: Artmed Editora, 2009. 27, 30

RAMOS, C. R. História da datilologia. **História da datilologia**, 2005. 27, 31

REED, R.; MARKS, R. J. **Neural smithing: supervised learning in feedforward artificial neural networks**. [S.l.]: Mit Press, 1999. 52

RODRIGUES, C. S.; VALENTE, F. Aspectos linguísticos da libras. **Curitiba: IESDE Brasil SA**, 2010. 30

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958. 47

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group, v. 323, n. 6088, p. 533, 1986. 52

SAGGIO, G.; RIILLO, F.; SBERNINI, L.; QUITADAMO, L. R. Resistive flex sensors: a survey. **Smart Materials and Structures**, IOP Publishing, v. 25, n. 1, p. 013001, 2015. 37

SAMARASINGHE, S. **Neural networks for applied sciences and engineering: from fundamentals to complex pattern recognition**. [S.l.]: CRC Press, 2016. 52

SARAWATE, N.; LEU, M. C.; OZ, C. A real-time american sign language word recognition system based on neural networks and a probabilistic model. **Turkish Journal of Electrical Engineering & Computer Sciences**, The Scientific and Technological Research Council of Turkey, v. 23, n. Sup. 1, p. 2017–2123, 2015. 32

SCHALKOFF, R. J. **Artificial neural networks**. [S.l.]: McGraw-Hill New York, 1997. 43, 48

SEGALA, R. R. et al. Tradução intermodal e intersemiótica/interlingual: português brasileiro escrito para língua brasileira de sinais. 2010. 27

SILVA, A. B. N. d. **Um modelo de unidade de medida inercial utilizando três acelerômetros triaxiais**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, 2013. 38

SILVA, G. M. da. Lendo e sinalizando textos. 2010. 25

SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas curso prático. **São Paulo: Artliber**, 2010. 44, 45, 47, 49, 51, 52, 55

- SOUSA, A. P. d. A. **Interpretação da língua gestual portuguesa**. Tese (Doutorado), 2012. [27](#), [29](#), [30](#)
- SOUZA, S. V. R. d. Calibração de acelerômetros mems com vistas a aplicação em uma plataforma euleriana. 2015. [39](#)
- SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: A simple way to prevent neural networks from overfitting. **The Journal of Machine Learning Research**, JMLR. org, v. 15, n. 1, p. 1929–1958, 2014. [53](#)
- STOKOE, W. C. **Sign and Culture: A Reader for Students of American Sign Language**. [S.l.]: ERIC, 1980. [21](#), [30](#)
- STROBEL, K. L.; FERNANDES, S. Aspectos linguísticos da libras. **PR, SEC**, 1998. [29](#)
- SUYKENS, J. A.; BRABANTER, J. D.; LUKAS, L.; VANDEWALLE, J. Weighted least squares support vector machines: robustness and sparse approximation. **Neurocomputing**, Elsevier, v. 48, n. 1-4, p. 85–105, 2002. [52](#)
- TAVARES, J. E. d. R.; LEITHARDT, V.; GEYER, C. F.; SILVA, J. S. Uma aplicação para o ensino da língua portuguesa para surdos utilizando o sensorlibras. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2009. v. 1, n. 1. [21](#), [30](#), [32](#)
- TORI, R.; KIRNER, C.; SISCOOTTO, R. A. **Fundamentos e tecnologia de realidade virtual e aumentada**. [S.l.]: Editora SBC, 2006. [23](#)
- TUBAIZ, N.; SHANABLEH, T.; ASSALEH, K. Glove-based continuous arabic sign language recognition in user-dependent mode. **IEEE Transactions on Human-Machine Systems**, IEEE, v. 45, n. 4, p. 526–533, 2015. [22](#)
- VERONESI, R. L. M. Rtrassoc51–móulo de comunicação i2c reconfigurável–i2c. 2006. [42](#)
- VINCENT, P.; LAROCHELLE, H.; LAJOIE, I.; BENGIO, Y.; MANZAGOL, P.-A. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. **Journal of Machine Learning Research**, v. 11, n. Dec, p. 3371–3408, 2010. [52](#)

WEBSTER, J. G.; EREN, H. **Measurement, instrumentation, and sensors handbook: spatial, mechanical, thermal, and radiation measurement**. [S.l.]: CRC press, 2014. [37](#)

WIRTH, N. **Digital circuit design for computer science students: an introductory textbook**. [S.l.]: Springer Science & Business Media, 2012. [42](#)

WOODMAN, O. J. **An introduction to inertial navigation**. [S.l.: s.n.], 2007. [40](#)

YANG, Q. Chinese sign language recognition based on video sequence appearance modeling. In: IEEE. **Industrial Electronics and Applications (ICIEA), 2010 the 5th IEEE Conference on**. [S.l.], 2010. p. 1537–1542. [22](#), [23](#)

ZHANG, L.-G.; CHEN, X.; WANG, C.; CHEN, Y.; GAO, W. Recognition of sign language subwords based on boosted hidden markov models. In: ACM. **Proceedings of the 7th international conference on Multimodal interfaces**. [S.l.], 2005. p. 282–287. [22](#)

