


**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**



**Utilização de Técnicas de Realidade Virtual na
Simulação de Próteses de Mão**

Fernando Eduardo Resende Mattioli

Fevereiro

2012

Utilização de Técnicas de Realidade Virtual na Simulação de Próteses de Mão

Fernando Eduardo Resende Mattioli

Texto apresentado à Universidade Federal de Uberlândia como parte dos requisitos para obtenção do título de Mestre em Ciências.

Prof. Edgard A. Lamounier Jr, PhD.

Orientador

Prof. Alexandre Cardoso, Dr.

Co-orientador

Prof. Alexandre Cardoso, Dr.

Coordenador do curso de Pós-Graduação

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**Utilização de Técnicas de Realidade Virtual na
Simulação de Próteses de Mão**

Fernando Eduardo Resende Mattioli

Texto apresentado à Universidade Federal de Uberlândia, perante a banca de examinadores abaixo, como parte dos requisitos necessários para a obtenção do título de Mestre em Ciências.

Banca Examinadora:

Prof. Edgard A. Lamounier Jr, PhD - Orientador (UFU)

Prof. Alexandre Cardoso, Dr. - Co-orientador (UFU)

Prof. Keiji Yamanaka, PhD (UFU)

Profa. Carla Maria Dal Sasso Freitas, Dra. (UFRGS)

*“If you wish to succeed, you must brave the risk of failure.”
(Garry Kasparov)*

*Dedico este trabalho aos meus avós
Nilton, Lourdes, Onofre e Nilza (in memorian),
meus maiores exemplos de luta, perseverança,
humildade e simplicidade.*

Agradecimentos

Gostaria de agradecer primeiramente a Deus, que me presenteou com a oportunidade de realizar este sonho.

Aos meus pais, Roberto e Neila, pelos bons exemplos, pela paciência e pelo permanente incentivo.

Ao meu irmão Leandro, pela valiosa ajuda, pela paciência e pela compreensão.

A minha namorada Camila, pelo carinho, compreensão e pelo apoio incondicional.

Aos professores Edgard e Alexandre, pela confiança, pela orientação, pela amizade e pela motivação.

Aos colegas do Programa de Pós-graduação em Engenharia Elétrica e do Laboratório de Computação Gráfica pelo apoio, pela amizade e pelos incontáveis momentos de alegria.

E a todos aqueles que direta ou indiretamente contribuíram para a realização deste trabalho.

Meus sinceros agradecimentos a todos vocês!

Resumo

MATTIOLI, Fernando E. R. *Utilização de Técnicas de Realidade Virtual na Simulação de Próteses de Mão*, Uberlândia, Faculdade de Engenharia Elétrica - UFU, 2012.

Palavras-chave: Realidade Virtual. Redes Neurais Artificiais. Reabilitação humana.

Nos últimos anos, sistemas de treinamento assistido por computador tem sido amplamente estudados no campo da reabilitação humana. Uma das tecnologias de maior impacto nesta classe de sistemas é a Realidade Virtual. Quando aplicada à saúde humana, a Realidade Virtual se apresenta como uma ferramenta adequada à simulação de ambientes de treinamento sem a exposição dos pacientes aos riscos associados ao ambiente real. Uma aplicação particular de Realidade Virtual na reabilitação humana são as próteses virtuais. Estes dispositivos têm sido utilizados para reduzir o grande esforço mental despendido por usuários de próteses mioelétricas, durante a fase de treinamento. Este esforço mental constitui apenas uma dentre as várias dificuldades encontradas pelos pacientes, que acabam culminando na desistência de muitos neste estágio do tratamento. Neste trabalho, a aplicação de Realidade Virtual em um sistema de treinamento para usuários de próteses de mão é apresentada. Para tal, a possibilidade de se utilizar Redes Neurais Artificiais como sistema de classificação em tempo real é discutida. Além disso, são apresentados um algoritmo de janelamento de sinais e uma arquitetura de comunicação entre o sistema de classificação e o ambiente virtual. Finalmente, é apresentado o protótipo desenvolvido para se investigar a aplicabilidade do sistema proposto em um contexto de processamento e classificação em tempo real.

Abstract

MATTIOLI, Fernando E. R. *On the Use of Virtual Reality Techniques in Hand Prosthesis Simulation*, Uberlândia, Faculty of Electrical Engineering - UFU, 2012.

Keywords: Virtual Reality. Artificial Neural Networks. Human rehabilitation.

In the past few years, computer-based training systems have been widely studied in the field of human rehabilitation. One of the cutting-edge technologies applied in this kind of system is Virtual Reality. In health applications, Virtual Reality presents itself as an appropriate tool to simulate training environments without exposing the patients to the real world associated risks. In particular, one application of Virtual Reality in human rehabilitation is in virtual prosthesis design. Virtual prosthetic devices have been used to reduce the great mental effort needed by patients fitted with myoelectric prosthesis, during the training stage. This effort is one of the main difficulties that lead patients to give up at this stage. In this paper, the application of Virtual Reality in a hand prosthesis training system is presented. To achieve this, the possibility of exploring Artificial Neural Networks in a real-time classification system is discussed. Also, a signal windowing algorithm and a communication architecture between the classification system and the virtual environment are presented. Finally, a prototype developed in order to investigate the application of the proposed system in a real-time processing and classification context is presented.

Publicações

A seguir, são apresentadas as publicações relacionadas a este trabalho.

Mattioli, F.E.R.; Lamounier Jr., E.A.; Cardoso, A.; Soares, A.B.; Andrade, A.O. **Classification of EMG signals using artificial neural networks for virtual hand prosthesis control**. In: 33rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC '11), 2011, Boston, Massachusetts, USA.

Pons, V.C.; Caetano, D.S.D.; Mattioli, F.E.R.; Nogueira, K.L.; Lamounier Jr., E.A.; Cardoso, A. **Comparison of neural networks applied to Augmented Reality for upper limb prosthesis simulation**. In: Anais do VIII Workshop de Realidade Virtual e Aumentada - WRVA'2011, 2011, Uberaba, MG, Brasil.

Mattioli, F.E.R.; Caetano, D.S.D.; Gomes, W.; Lamounier Jr., E.A.; Cardoso, A.; **Utilização de redes neurais para a classificação de sinais EMG aplicados no controle de próteses virtuais de mão**. In: Anais do VII Workshop de Realidade Virtual e Aumentada - WRVA'2010, 2010, São Paulo, SP, Brasil.

Mattioli, F.E.R.; Lamounier Jr., E.A.; Cardoso, A.; Alves, N.M.M.; **Uma proposta para o desenvolvimento ágil de ambientes virtuais**. In: Anais do VI Workshop de Realidade Virtual e Aumentada - WRVA'2009, 2009, Santos, SP, Brasil.

Sumário

Lista de Figuras	vi
Lista de Tabelas e Quadros	ix
Lista de Abreviaturas	x
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos e Metas	2
1.3 Organização da Dissertação	3
2 Fundamentos	4
2.1 Introdução	4
2.2 Fundamentos de Engenharia Biomédica e Redes Neurais Artificiais . .	4
2.2.1 Próteses de mão	5
2.2.1.1 Próteses passivas	5
2.2.1.2 Próteses neuromotoras	5
2.2.1.3 Próteses mioelétricas	7
2.2.2 Controle de próteses mioelétricas	8
2.2.2.1 Controle autônomo	8
2.2.2.2 Controle proporcional	9
2.2.2.3 Controle por linguagem de comando	9
2.2.3 O sinal eletromiográfico	9
2.2.4 Processamento de sinais eletromiográficos	10
2.2.4.1 Modelo autoregressivo	10
2.2.4.2 Características no domínio do tempo	11

2.2.5	Redes neurais para a classificação de sinais biomédicos	13
2.2.5.1	Redes MLP	14
2.2.5.2	Redes LVQ	17
2.2.5.3	Redes SOM	20
2.3	Fundamentos de Realidade Virtual	22
2.3.1	Ambientes virtuais utilizados em reabilitação	22
2.4	Considerações finais	24
3	Trabalhos Correlatos	25
3.1	Introdução	25
3.2	Reconhecimento de padrões EMG em tempo real	25
3.3	Controle em tempo real de uma mão virtual	26
3.4	Prótese MANUS	27
3.5	Classificação de sinais EMG utilizando características no domínio do tempo	30
3.6	RV e RA aplicados à simulação de próteses de membros superiores . .	31
3.7	Resumo comparativo dos trabalhos analisados	32
3.8	Considerações finais	33
4	Especificação do sistema proposto	36
4.1	Introdução	36
4.2	Requisitos funcionais	37
4.2.1	Configuração dos parâmetros do classificador	38
4.2.2	Teste do classificador	38
4.2.3	Controle do ambiente virtual	38
4.3	Requisitos não funcionais	39
4.3.1	Classificação dos movimentos	39
4.3.2	Tempo de resposta	39
4.3.3	Simulação realística	40
4.4	Requisitos de performance em tempo real	40
4.4.1	Aquisição de dados	41
4.4.2	Janelamento dos sinais	41
4.5	Diagramas de casos de uso	41

4.5.1	Tratamento dos dados	41
4.5.2	Configuração/teste do classificador	43
4.5.3	Processamento em tempo real	44
4.6	Diagrama de classes	45
4.7	Considerações finais	46
5	Detalhes da Implementação	47
5.1	Introdução	47
5.2	Processo de desenvolvimento	47
5.3	Aquisição de sinais	48
5.4	Classificador de sinais	49
5.4.1	Classificador LVQ	50
5.4.1.1	Método de classificação	50
5.4.1.2	Arquitetura	50
5.4.1.3	Configuração do classificador	51
5.4.1.4	Algoritmo de treinamento	54
5.4.2	Classificador MLP	54
5.4.2.1	Arquitetura	55
5.4.2.2	Algoritmo de treinamento	57
5.5	Ambiente virtual	58
5.5.1	Mão virtual	58
5.5.2	Movimentos	58
5.5.3	Comunicação com o sistema de classificação	60
5.6	Processamento em tempo real	60
5.6.1	Janelamento	62
5.6.2	Extração de características	64
5.6.3	Classificação	65
5.7	Construção do protótipo	66
5.8	Considerações finais	67
6	Discussão dos resultados	68
6.1	Performance do classificador LVQ	68
6.1.1	Influência dos parâmetros de configuração	68

6.1.1.1	Taxa de aprendizagem (α)	69
6.1.1.2	Taxa de decaimento de α	70
6.1.1.3	Tolerância	72
6.1.2	Influência do número de unidades de saída	73
6.1.3	Influência das características do sinal	76
6.2	Performance do classificador MLP	78
6.2.0.1	Taxa de aprendizagem (α)	79
6.2.0.2	Número de neurônios da camada escondida	80
6.3	Considerações finais	81
7	Conclusões e trabalhos futuros	83
7.1	Introdução	83
7.2	Conclusões	83
7.3	Trabalhos futuros	84
7.4	Considerações finais	85
	Referências bibliográficas	85

Lista de Figuras

2.1	Prótese Wilmer	6
2.2	Protótipo de prótese neuromotora	7
2.3	Prótese mioelétrica SensorHand Speed	8
2.4	Rede MLP - Arquitetura.	15
2.5	Rede LVQ - Arquitetura.	18
2.6	Paciente utilizando o sistema SAIL.	23
2.7	Exercícios <i>Peg board</i> e arremesso/captura de bola.	24
3.1	Reconhecimento de padrões EMG.	25
3.2	Usuário da prótese MANUS.	28
3.3	Palavra de comando da prótese MANUS.	28
3.4	Ambiente virtual de treinamento.	29
3.5	Arquitetura do sistema [Herle et al. 2008]	30
3.6	Prótese virtual	31
3.7	Arquitetura do sistema [Nogueira 2007]	31
3.8	Ambiente em Realidade Aumentada.	32
4.1	Casos de uso: tratamento dos dados.	42
4.2	Exemplo de arquivo de dados.	42
4.3	Exemplos de vetores de características: <i>Mean Absolute Value</i> - MAV, <i>Mean Absolute Value Slope</i> - MAVS, <i>Zero Crossing</i> - ZC, <i>Slope Sign</i> <i>Changes</i> - SSC e <i>Waveform Length</i> - WL.	43
4.4	Casos de uso: configuração/teste do classificador.	44
4.5	Casos de uso: simulação em tempo real.	45
4.6	Diagrama de classes.	45

5.1	Processo de desenvolvimento de SRV.	48
5.2	Exemplo de sinal EMG.	49
5.3	Arquitetura da rede LVQ utilizada.	50
5.4	Interface de configuração do classificador.	52
5.5	Painel <i>Configuration</i>	53
5.6	Painel <i>Training patterns</i>	53
5.7	Painel <i>Control</i>	53
5.8	Painel <i>Open signal</i>	54
5.9	Algoritmo de treinamento da rede LVQ.	55
5.10	Arquitetura da rede MLP implementada.	56
5.11	Braço virtual utilizado.	59
5.12	Armadura adaptada ao braço virtual.	59
5.13	Flexão do pulso.	59
5.14	Extensão do pulso.	60
5.15	Pronação do pulso.	60
5.16	Flexão dos dedos.	60
5.17	Comunicação entre o ambiente virtual e o sistema de classificação. . .	61
5.18	Simulador de aquisição/classificação em tempo real.	61
5.19	Exemplo de aplicação do operador TKEO.	63
5.20	Estratégia de classificação.	65
5.21	Arquitetura do protótipo.	66
6.1	Eficiência da rede x taxa de aprendizagem.	70
6.2	Tempo de treinamento x taxa de aprendizagem.	71
6.3	Eficiência da rede x decaimento de α	71
6.4	Tempo de treinamento x decaimento de α	72
6.5	Eficiência da rede x tolerância.	73
6.6	Tempo de treinamento x tolerância.	73
6.7	Eficiência da rede x número de unidades de saída.	74
6.8	Tempo de treinamento x número de unidades de saída.	75
6.9	Resultados dos testes com 2 características.	76
6.10	Resultados dos testes com 3 características.	77
6.11	Resultados dos testes com 4 características.	77

6.12 Resultados dos testes com 5 características.	78
6.13 Eficiência da rede x taxa de aprendizagem.	79
6.14 Tempo de treinamento x taxa de aprendizagem.	80
6.15 Eficiência da rede x neurônios na camada escondida.	81
6.16 Tempo de treinamento x neurônios na camada escondida.	81

Lista de Tabelas e Quadros

2.1	Resumo comparativo das redes neurais artificiais apresentadas	21
3.1	Características dos trabalhos correlatos	34
3.2	Resumo comparativo dos trabalhos correlatos	35
5.1	Saída da rede MLP	56
6.1	Resumo comparativo dos trabalhos correlatos e do presente trabalho .	82

Lista de Abreviaturas

A/D	Analógico/Digital
AG	Algoritmo Genético
AR	Autoregressivo
AVC	Acidente vascular cerebral
BP	<i>Backpropagation</i>
EMG	Eletromiográfico
KNN	<i>K-nearest neighbors</i>
LVQ	<i>Learning vector quantization</i>
MAVS	<i>Mean absolute value slope</i>
MAV	<i>Mean absolute value</i>
MLP	<i>Multi-layer perceptron</i>
MVS	<i>Majority voting scheme</i>
PCA	<i>Principal component analysis</i>
RNA	Redes Neurais Artificiais
RV	Realidade Virtual
SAIL	<i>Stimulation Assistance through Iterative Learning</i>
sEMG	Sinal eletromiográfico de superfície
SOFM	<i>Self-organizing feature map</i>

SOM *Self-organizing maps*

SRV *Sistemas de Realidade Virtual*

SSC *Slope sign changes*

TKEO *Teager-Kaiser energy operator*

UML *Unified Modeling Language*

WL *Waveform length*

ZC *Zero crossing*

Capítulo 1

Introdução

1.1 Motivação

Um dos mais complexos e mais extraordinários organismos encontrados na natureza é o corpo humano. Constituído pela interligação de diversos sistemas, o corpo humano possibilita aos seres humanos a execução das múltiplas funções mecânicas, físicas e bioquímicas imprescindíveis à sua sobrevivência. Aliadas ao desenvolvimento das faculdades mentais, a robustez e a adaptabilidade do corpo humano foram responsáveis pela manutenção da espécie humana e pelo aperfeiçoamento de suas habilidades psíquicas e motoras.

A privação de determinada função do corpo humano possui um impacto significativo na qualidade de vida de qualquer pessoa. Nesse sentido, uma amputação sofrida por um indivíduo, seja ela cirúrgica ou traumática, pode comprometer seriamente a realização de suas atividades diárias, o que pode resultar no aparecimento de graves complicações psicológicas.

No mundo todo, o número de amputados aumenta de 150.000 a 200.000 a cada ano. Cerca de 30% destes sofrem amputação do membro superior. Estudos demonstram ainda que 70% das amputações traumáticas envolvem membros superiores [Toledo et al. 2009].

No Brasil, a maior parte das cirurgias para retirada de membros é resultante do diabetes (cerca de 70% das cirurgias, segundo estatísticas do Ministério da Saúde). Esta porcentagem corresponde a cerca de 55 mil amputações por ano [Globo.com 2010].

Uma prótese é um dispositivo artificial que tem como objetivo substituir determinada parte do corpo. No caso de um indivíduo amputado, a prótese pode restaurar a funcionalidade e a aparência do membro perdido, reduzindo as limitações do indivíduo e permitindo que este retome sua vida normal.

Próteses mioelétricas de mão consistem em próteses de membro superior (ou extremidade superior) controladas a partir do sinal elétrico dos músculos residuais. Estas próteses possuem uma série de funcionalidades e, portanto, requerem estratégias de controle robustas e computacionalmente eficientes [Chu, Moon e Mun 2006]. Neste sentido, a habilidade dos usuários em controlar as próteses desempenha um papel determinante na performance de utilização destes dispositivos.

Nos últimos anos, tanto a Medicina como outras áreas relacionadas à saúde humana têm sido beneficiadas pelos avanços tecnológicos apresentados pela Realidade Virtual (RV) [Costa e Ribeiro 2009]. Mais especificamente, quando aplicada à reabilitação humana, a natureza intuitiva da interação homem-máquina proporcionada pela RV favorece o treinamento de habilidades cognitivas e motoras dos pacientes [Weiss et al. 2004].

A utilização de técnicas de RV no treinamento de usuários de próteses mioelétricas apresenta-se como uma ferramenta complementar que favorece a adaptação dos usuários aos membros artificiais [Herle et al. 2008]. Apesar do custo ainda elevado destes dispositivos, um grande problema enfrentado pelos usuários é a adaptação ao controle das próteses, sendo observada a desistência de muitos pacientes durante o período de treinamento [Herle et al. 2008]. Além de possibilitar a avaliação da eficiência de diferentes sistemas de controle, a utilização de RV na simulação de próteses mioelétricas ameniza este problema fornecendo um canal de *feedback* visual aos pacientes. Desta forma, a utilização de próteses virtuais durante a fase de treinamento reduz significativamente o grande esforço mental despendido pelos usuários nesta etapa [Sebelius et al. 2005].

1.2 Objetivos e Metas

Sistemas de treinamento para usuários de próteses de mão têm sido investigados por alguns autores nos últimos anos [Pons et al. 2005, Sebelius et al. 2005, Chu, Moon e

Mun 2006]. Dentre os desafios encontrados por estes autores destacam-se o processamento dos sinais de controle, os algoritmos de discriminação dos movimentos e a resposta em tempo real destes sistemas. Um ambiente de treinamento em RV, aplicado neste contexto, deve oferecer ao paciente o *feedback* visual necessário, além de fornecer uma resposta que satisfaça os requisitos temporais da aplicação. Neste sentido, o objetivo deste trabalho é desenvolver um ambiente de treinamento em RV que possibilite a simulação e o controle de próteses virtuais de mão, visando a simplicidade do processamento dos sinais de controle e o tempo de resposta do sistema de classificação. Para tal, foram traçadas as seguintes metas:

- Desenvolver um sistema para a classificação de sinais eletromiográficos relacionados aos movimentos da mão.
- Projetar a comunicação entre o sistema de classificação e um ambiente virtual de treinamento, compatível com os requisitos de resposta em tempo real da aplicação.

1.3 Organização da Dissertação

A presente dissertação é constituída de 7 capítulos, descritos a seguir.

No Capítulo 1 são apresentados a motivação para o desenvolvimento do trabalho, os objetivos e metas propostos e a estruturação do trabalho.

No Capítulo 2 são apresentados os principais fundamentos biomédicos e tecnológicos relacionados ao trabalho desenvolvido.

No Capítulo 3 é apresentado o estado da arte da linha de pesquisa principal deste trabalho.

Nos Capítulos 4 e 5 são apresentados a especificação do sistema proposto e os principais detalhes de implementação.

O Capítulo 6 apresenta uma breve discussão dos resultados obtidos a partir do desenvolvimento do sistema proposto.

Finalmente, no Capítulo 7, são apresentadas as conclusões e as perspectivas de trabalhos futuros.

Capítulo 2

Fundamentos

2.1 Introdução

Neste capítulo, serão abordados alguns dos aspectos biomédicos e tecnológicos relacionados ao presente trabalho.

2.2 Fundamentos de Engenharia Biomédica e Redes Neurais Artificiais

Uma prótese é um dispositivo que tem como principal função a substituição (estética ou funcional) de determinado membro. Neste sentido, o desenvolvimento de próteses antropomórficas requer a construção de modelos matemáticos interdisciplinares, baseados em conceitos de anatomia, fisiologia, dinâmica e cinemática [Nogueira 2007].

A tecnologia de construção de próteses passou por grandes avanços nas últimas décadas [Marks e Michael 2001]. Atualmente, usuários de próteses são capazes de desempenhar um grande número de tarefas antes inacessíveis a este grupo, como por exemplo a prática de esportes especializados e algumas atividades de recreação.

No entanto, a reabilitação de pessoas que sofreram amputação ainda é um grande problema social nos dias atuais. Dentre os principais fatores que contribuem para este cenário estão o alto custo dos dispositivos, as limitações das próteses disponíveis atualmente no mercado e a dificuldade de adaptação de alguns usuários às próteses, causada pelo desconforto proporcionado ou pela dificuldade em controlar o dispositivo.

2.2.1 Próteses de mão

Uma das maiores dificuldades encontradas ao se desenvolver próteses de mão é reproduzir a flexibilidade da mão humana nestes dispositivos. Além do elevado número de graus de liberdade da mão humana, esta flexibilidade se deve ao fato de o ser humano alterar a forma da mão de acordo com a tarefa a ser realizada [Kyberd et al. 2001]. Além dos desafios associados às características mecânicas (construção de mãos mecânicas multi-funcionais), os mecanismos de comando dos dispositivos prótéticos também constituem uma importante área de pesquisa, como pode ser constatado nos trabalhos de Zecca [Zecca et al. 2002], Light [Light et al. 2002], Pons [Pons et al. 2005] e Su [Su et al. 2007].

Nesta seção, são apresentados os princípios de funcionamento das próteses passivas, neuromotoras e mioelétricas.

2.2.1.1 Próteses passivas

Próteses não-funcionais ou passivas são dispositivos semi-móveis ou totalmente imóveis cujo principal objetivo é a restauração da função estética do membro amputado [Nogueira 2007]. Alguns dispositivos, tais como a prótese Wilmer [Plettenburg 2008], oferecem a função de preensão por meio de um sistema mecânico de abertura e fechamento dos dedos. No caso da prótese Wilmer, apresentada na Figura 2.1, a abertura se dá pela pressão de determinado objeto contra as pontas dos dedos da mão artificial. Uma leve inclinação do objeto em questão provoca o fechamento do dispositivo [Plettenburg 2008].

2.2.1.2 Próteses neuromotoras

Próteses neuromotoras têm como objetivo substituir ou restaurar funções motoras a partir dos sinais relacionados à atividade cerebral. Estes dispositivos podem ser aplicados na reabilitação de pacientes cuja atividade cerebral não é capaz de produzir movimento, seja por lesões na medula espinhal, lesões nos nervos ou lesões nos próprios músculos [Hochberg et al. 2006].

Uma prótese neuromotora é constituída de 3 partes essenciais [Hochberg et al. 2006]:




Figura 2.1: Prótese Wilmer [Plettenburg 2008]

- Um elemento sensor, capaz de detectar a atividade neuronal;
- Um decodificador que traduz a atividade neuronal em sinais de comando;
- Um sistema que aciona os efetadores de acordo com o movimento desejado.

A detecção da atividade neuronal pode ser realizada por métodos invasivos ou não-invasivos. Projetos que utilizam interfaces invasivas (como apresentado por Hochberg [Hochberg et al. 2006]), são limitados por diversas dificuldades técnicas e envolvem riscos clínicos significativos, pois requerem que os eletrodos sejam implantados no córtex cerebral do paciente [Wolpaw e McFarland 2004]. Métodos não-invasivos como, por exemplo, o processamento de sinais eletroencefalográficos, não apresentam tantos riscos clínicos quanto os métodos invasivos. No entanto, a grande quantidade de informações a serem processadas (devido ao registro da atividade simultânea de milhões de neurônios) impõe severas limitações à utilização destes métodos em sistemas em tempo-real [König e Verschure 2002].

Na Figura 2.2 é apresentado um protótipo de prótese neuromotora. Neste dispositivo, eletrodos conectados aos nervos do braço esquerdo do paciente possibilitam que este realize, dentre outras ações, o controle independente dos dedos artificiais [The Italian Tribune 2011].




Figura 2.2: Protótipo de prótese neuromotora¹.

2.2.1.3 Próteses mioelétricas

Uma das abordagens mais populares para o controle de próteses é baseada na utilização de sinais eletromiográficos (EMG) dos músculos remanescentes como sinais de controle dos membros artificiais [Lamounier et al. 2010]. Estes sinais consistem na manifestação elétrica da atividade neuromuscular associada à contração de determinado músculo e serão mais detalhados na seção 2.2.3. Atualmente, a maioria das próteses transradiais funcionais (próteses que substituem parte do membro superior após amputação abaixo do cotovelo) utiliza sinais EMG do antebraço para controlar a abertura e o fechamento das mãos artificiais [Li, Schultz e Kuiken 2010].

Em comparação às próteses tipo “gancho”, as primeiras próteses mioelétricas construídas proporcionavam ao usuário mais graus de liberdade de movimento. No entanto, o número de graus de liberdade era limitado pela habilidade do usuário em assimilar movimentos não-naturais (para produzir os sinais de comando) e pela performance do sistema de classificação ao decodificar estes diferentes sinais de comando [Craelius, Abboudi e Newby 1999]. Em alguns dispositivos, por exemplo, os usuários são capazes de ativar o modo de rotação do pulso efetuando a contração simultânea de alguns músculos do antebraço [Li, Schultz e Kuiken 2010]. Deve-se

¹Foto extraída de: *The Italian Tribune: Italian Scientists Give Amputee Thought-Controlled Robotic Hand*, disponível em <http://theitaliantribune.com/?p=119>.

ressaltar, contudo, que a adaptação dos usuários aos comandos requer um processo de treinamento, uma vez que o controle de diferentes funções utilizando as mesmas contrações musculares não se dá de forma natural [Li, Schultz e Kuiken 2010].

Na Figura 2.3, é apresentada uma prótese mioelétrica de mão.



Figura 2.3: Prótese mioelétrica SensorHand Speed [MYOBOCK® System 2011]

2.2.2 Controle de próteses mioelétricas

Atualmente, diversas abordagens estão disponíveis para o controle de próteses mioelétricas. No entanto, os sistemas de controle destes dispositivos podem ser classificados em dois tipos principais: autônomos ou voluntários [Okuno, Yoshida e Akazawa 2005]. Nesta seção, serão apresentadas as principais características de cada um destes sistemas de controle.

2.2.2.1 Controle autônomo

Em um sistema de controle autônomo, a movimentação de cada parte da prótese é feita automaticamente, a partir de uma instrução simples dada pelo usuário [Okuno, Yoshida e Akazawa 2005]. Por exemplo, a partir da contração de determinado músculo, uma prótese de mão com controle autônomo fechará os dedos da mão mecânica, automaticamente, a uma velocidade constante. Quando detectada a contração de outro músculo, os dedos da mão mecânica se abrirão. Em alguns dispositivos, tais como

a *Southampton Hand* [Kyberd et al. 2001] e a *SensorHand* [HealthCare 2011], durante a captura de determinado objeto, a força de preensão é ajustada, automaticamente, quando é detectado um deslizamento do objeto capturado.

2.2.2.2 Controle proporcional

Próteses de mão com controle proporcional apresentam velocidade e força de preensão proporcionais à intensidade dos sinais de ativação coletados nos músculos [Hesse e Herrmann 2010]. A principal vantagem desta abordagem de controle é sua semelhança com a forma natural de controle dos membros no corpo humano. Diversos autores, tais como Nielsen et. al. [Nielsen et al. 2009] e Jiang et. al. [Jiang, Englehart e Parker 2009] investigaram o processamento de sinais EMG visando o controle proporcional de próteses de mão.

2.2.2.3 Controle por linguagem de comando

Dispositivos com controle por linguagem de comando são utilizados quando o controle analógico (proporcional) apresenta limitações devido à quantidade de movimentos proporcionada pelo dispositivo. Trata-se de uma abordagem de controle alternativa ao processamento simultâneo de múltiplos canais EMG, em que o sinal de comando consiste em sucessivas contrações (*bursts*) do músculo em questão. As sucessivas contrações formam então uma palavra binária que é decodificada, resultando na execução do movimento correspondente. Esta foi a abordagem utilizada no controle da prótese MANUS [Pons et al. 2005].

2.2.3 O sinal eletromiográfico

O sinal eletromiográfico (EMG) consiste na manifestação elétrica da atividade neuromuscular associada à contração de determinado músculo [Soares et al. 2003]. Apesar da baixa amplitude do sinal EMG, sua propagação permite que este seja detectado em determinados pontos na superfície da pele (EMG de superfície ou sEMG), o que viabiliza sua aplicação como sinal de controle de membros artificiais [Li, Schultz e Kuiken 2010].

2.2.4 Processamento de sinais eletromiográficos

A maioria dos sinais biológicos é encontrada, na natureza, em sua forma contínua. Desta forma, quando estes sinais são extraídos da natureza, a informação extraída é representada por um sinal contínuo. Após os processos de discretização e conversão analógico-digital (A/D), a informação biológica é representada por um sinal digital discreto, podendo ser processada e manipulada em sistemas computacionais. Nesta seção, serão apresentadas algumas das principais abordagens de processamento de sinais eletromiográficos.

2.2.4.1 Modelo autoregressivo

Um modelo autoregressivo consiste em uma representação de determinado sinal que depende apenas dos valores de saída armazenados anteriormente pelo sistema. Em um modelo autoregressivo, o valor da variável em determinado instante ($\hat{y}(n)$) pode ser estimado a partir do valor da variável em instantes anteriores ($y(n-1), y(n-2), \dots$). A equação 2.1 define o modelo autoregressivo [Soares et al. 2003].

$$\hat{y}(n) = \sum_{m=1}^M a_m(n)y(n-m) + e(n) \quad (2.1)$$

sendo \hat{y} o valor estimado no instante n , a_m o coeficiente autoregressivo (AR) de ordem m , $e(n)$ o erro estimado e M a ordem do modelo (número de coeficientes a_m).

Uma estratégia para o cálculo dos coeficientes autoregressivos e do erro estimado é apresentada a seguir [Akay 1994].

1. Inicialização dos coeficientes em 0.
2. Cálculo do valor estimado ($\hat{y}(n)$) do sinal de entrada ($y(n)$).

$$\hat{y}(n) = \sum_{m=1}^M a_m(n)y(n-m) \quad (2.2)$$

3. Cálculo do erro estimado.

$$e(n) = y(n) - \hat{y}(n) \quad (2.3)$$

4. Atualização dos coeficientes AR.

$$a_m(n+1) = a_m(n) - 2\mu e(n)y(n-m) \quad (2.4)$$

sendo μ uma constante de convergência, normalmente representada por um pequeno valor positivo (da ordem de 10^{-3}) [Soares et al. 2003, Hefftner, Zucchini e Jaros 1988].

2.2.4.2 Características no domínio do tempo

Uma outra abordagem para a análise de sinais EMG no domínio do tempo consiste na extração de características temporais do sinal. Como discutido em [Herle et al. 2008], a complexidade e a aleatoriedade do sinal EMG impossibilitam que o classificador seja alimentado diretamente com os sinais. Uma possível solução para este problema é alimentar o classificador com um vetor de características extraídas do sinal EMG. No entanto, deve-se ressaltar que a escolha das características corretas afetará diretamente o desempenho do classificador. A seguir, são apresentadas as características utilizadas neste trabalho, bem como em outros trabalhos correlatos, a saber, [Mattioli et al. 2010], [Li, Schultz e Kuiken 2010], [Herle et al. 2008] e [Hudgins, Parker e Scott 1993].

- MAV (*Mean Absolute Value*)

MAV representa a média dos valores absolutos das amostras de determinado segmento do sinal analisado. A Equação 2.5 é utilizada para calcular este valor.

$$\bar{x}_i = \frac{1}{S} \sum_{m=1}^S |x_m|, \quad (2.5)$$

sendo $i = 1 \dots I$ o número do segmento, S o número de amostras por segmento e x_m a m -ésima amostra no segmento i .

- MAVS (*Mean Absolute Value Slope*)

A inclinação da média dos valores absolutos (MAVS) consiste na diferença entre a MAV de dois segmentos adjacentes, e é calculada pela relação:

$$\Delta \bar{x}_i = \bar{x}_{i+1} - \bar{x}_i, \quad (2.6)$$

sendo i e $i + 1$ dois segmentos adjacentes e $i = 1 \dots I - 1$.

- ZC (*Zero Crossing*)

O número de cruzamentos em zero (ZC) é uma medida de frequência que pode ser obtida contando-se o número de vezes em que uma forma de onda corta a reta $y = 0$. Um limiar foi incluído para se filtrar os cruzamentos em zero induzidos por ruídos. Assim como em Herle [Herle et al. 2008], neste trabalho foi utilizado um limiar $\epsilon = 10^{-6}$. O contador de cruzamentos em zero é incrementado quando a condição

$$\begin{aligned} &\{x_m > 0 \text{ e } x_{m+1} < 0\} \text{ ou} \\ &\{x_m < 0 \text{ e } x_{m+1} > 0\} \text{ e} \\ &|x_m - x_{m+1}| \geq \epsilon \end{aligned} \quad (2.7)$$

é satisfeita para duas amostras consecutivas x_m e x_{m+1} .

- SSC (*Slope Sign Changes*)

As alterações no sinal da inclinação SSC possibilitam uma outra medida do conteúdo em frequência do sinal. O mesmo limiar utilizado no contador ZC foi aplicado ao contador SSC, que é incrementado quando a condição 2.8, abaixo, é verdadeira para três amostras consecutivas x_{m-1} , x_m e x_{m+1} .

$$\begin{aligned} &x_m > x_{m-1} \text{ e } x_m > x_{m+1} \text{ ou} \\ &x_m < x_{m-1} \text{ e } x_m < x_{m+1} \text{ e} \\ &|x_m - x_{m+1}| \geq \epsilon \text{ ou } |x_m - x_{m-1}| \geq \epsilon \end{aligned} \quad (2.8)$$

- WL (*Waveform Length*)

O comprimento da forma de onda (WL) é utilizado para se analisar a complexidade da forma de onda em cada segmento. Este parâmetro consiste no comprimento cumulativo da forma de onda dentro do segmento em questão. A Equação 2.9 fornece uma medida de amplitude, frequência e duração do segmento em um único parâmetro:

$$WL = \sum_{m=1}^S |\Delta x_m|, \quad (2.9)$$

com $\Delta x_m = x_m - x_{m-1}$, sendo x_m e x_{m-1} duas amostras adjacentes.

2.2.5 Redes neurais para a classificação de sinais biomédicos

Redes Neurais Artificiais (RNA) são sistemas capazes de reconhecer e classificar padrões a partir de um modelo de aprendizagem baseado no aprendizado humano [Fausett 1994]. Uma característica marcante das RNA é sua capacidade de generalização: após uma fase de treinamento, na qual alguns padrões de entrada (juntamente com sua respectiva classificação) são apresentados e processados pela rede, esta pode ser testada com padrões diferentes daqueles utilizados em treinamento, classificando-os adequadamente. Os principais elementos que caracterizam uma RNA são [Fausett 1994]:

- A arquitetura da rede, representada pelo padrão de conexões entre seus neurônios (unidades fundamentais da RNA);
- O algoritmo de treinamento ou aprendizagem da rede;
- A função de ativação.

Cada conexão entre dois neurônios é representada por um peso, que determina a força da conexão. O mecanismo de aprendizagem da rede consiste na atualização sistemática dos pesos, controlada pela taxa de aprendizagem (α). Um ou mais critérios de parada são utilizados para interromper o treinamento, quando condições satisfatórias são atingidas. A função de ativação é aplicada a determinado padrão apresentado à rede - ponderado pelos pesos das conexões - produzindo a saída correspondente àquele padrão de entrada [Russell e Norvig 2010, Fausett 1994].

Nos últimos anos, as RNA têm sido utilizadas em diversas áreas da Engenharia Biomédica tais como detecção de arritmias cardíacas [Mar et al. 2011, Hosseini, Luo e Reynolds 2006], construção de interfaces homem-máquina [Choi et al. 2009] e controle de próteses [Nielsen et al. 2011, Lujan e Crago 2009].

O sinal EMG consiste em um processo estocástico, de alta complexidade, sem regra de formação definida [Andrade 2000, Soares et al. 2003]. Além disso, as características do sinal EMG estão fortemente relacionadas às condições físicas do indivíduo [Kuribayashi et al. 1993]. Desta forma, um classificador aplicado à discriminação de sinais EMG deve: 1) ser capaz de realizar o mapeamento não linear do sinal; 2) oferecer um processo rápido e eficiente de recalibração, para adaptar o sistema de classificação às condições físicas do indivíduo.

A utilização de RNA na classificação de sinais EMG tem sido investigada há alguns anos, por vários pesquisadores [Hiraiwa, Shimohara e Tokunaga 1989, Matsu-mura et al. 2002, Gutierrez e Munoz 2011, Andrade 2000]. Dentre as redes mais utilizadas neste tipo de aplicação estão as redes MLP (*multi-layer perceptron*) com retropropagação do erro (*backpropagation* - BP) [Sun, Chen e Tian 2011, Yang, Yantao e Yantao 2010, Muceli, Jiang e Farina 2010, Nielsen et al. 2009], redes LVQ (*learning vector quantization*) [Liu e Luo 2008, Guo et al. 2006], e mapas auto-organizáveis (*self-organizing maps* - SOM) [Kiso e Seki 2010, Huang et al. 2003].

As próximas seções apresentam uma breve descrição do funcionamento de cada uma destas redes neurais artificiais.

2.2.5.1 Redes MLP

Redes MLP (*multi-layer perceptron*) são redes neurais multicamadas cujo mecanismo de aprendizagem consiste na retropropagação do erro *backpropagation* [Sun, Chen e Tian 2011]. O método de treinamento das redes MLP consiste em um método de gradiente descendente, baseado na redução do erro quadrático total da saída da rede [Fausett 1994]. A popularidade e a capacidade de generalização das redes MLP motivaram sua utilização em diversas áreas, tais como aproximação de funções matemáticas, reconhecimento de padrões e mineração de dados (*data mining*) [Yang, Yantao e Yantao 2010, Sun, Chen e Tian 2011].

Arquitetura

Na Figura 2.4 é apresentada a arquitetura de uma rede MLP com uma camada escondida de neurônios. Nesta figura:

- $X_i, i = 1, \dots, n$ representam as unidades da camada de entrada;
- $Z_j, j = 1, \dots, p$ representam as unidades da camada escondida;
- $Y_k, k = 1, \dots, m$ representam as unidades da camada de saída;
- v_{np} representam os pesos das conexões entre a camada de entrada e a camada escondida;
- w_{pm} representam os pesos das conexões entre a camada escondida e a camada de saída;
- Os neurônios representados por “1” constituem os “bias”, representando conexões com ativação constante igual a 1 [Fausett 1994].




Figura 2.4: Rede MLP - Arquitetura [Fausett 1994].

Algoritmo de treinamento

O algoritmo de treinamento da rede MLP pode ser resumido pelos passos apresentados a seguir [Fausett 1994].

Passo 0: Inicialização dos pesos.

Passo 1: Enquanto a condição de parada for falsa, execute os passos 2-9.

Passo 2: Para cada padrão de treinamento, execute os passos 3-8.

Feedforward:

Passo 3: Cada unidade de entrada ($X_i, i = 1, \dots, n$) recebe o padrão de entrada x_i e o propaga para as unidades da camada escondida.

Passo 4: Cada unidade da camada escondida ($Z_j, j = 1, \dots, p$) calcula sua entrada ponderada,

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij},$$

aplica sua função de ativação para calcular seu sinal de saída,

$$z_j = f(z_in_j),$$

e envia este sinal para as unidades da camada de saída.

Passo 5: Cada unidade da camada de saída ($Y_k, k = 1, \dots, m$) soma seu sinal de entrada,

$$y_in_k = w_{0k} + \sum_{j=1}^p z_j w_{jk},$$

e aplica sua função de ativação para calcular seu sinal de saída,

$$y_k = f(y_in_k).$$

Retropropagação do erro:

Passo 6: Cada unidade da camada de saída ($Y_k, k = 1, \dots, m$) recebe um padrão alvo (t_k) correspondente ao padrão de treinamento, calcula o termo de informação do erro,

$$\delta_k = (t_k - y_k) f'(y_in_k),$$

calcula o vetor de correção dos pesos,

$$\Delta w_{jk} = \alpha \delta_k z_j,$$

e envia δ_k para as unidades da camada escondida.

Passo 7: Cada unidade da camada escondida ($Z_j, j = 1, \dots, p$) soma suas entradas “delta”,

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk},$$

calcula o termo de informação do erro,

$$\delta_j = \delta_{in_j} f'(z_{in_j}),$$

e calcula o vetor de correção dos pesos,

$$\Delta v_{ij} = \alpha \delta_j x_i.$$

Atualização dos pesos:

Passo 8: Cada unidade da camada de saída ($Y_k, k = 1, \dots, m$)

atualiza seus pesos ($j = 0, \dots, p$):

$$w_{jk}(\text{novo}) = w_{jk}(\text{anterior}) + \Delta w_{jk}$$

Cada unidade da camada escondida ($Z_j, j = 1, \dots, p$)

atualiza seus pesos ($i = 0, \dots, n$):

$$v_{ij}(\text{novo}) = v_{ij}(\text{anterior}) + \Delta v_{ij}$$

Passo 9: Testa condição de parada.

No algoritmo apresentado anteriormente, é possível identificar as 3 fases principais do processo de treinamento: alimentação direta (*feedforward*), retropropagação do erro e atualização dos pesos. A condição de parada pode ser definida, por exemplo, a partir do erro quadrático máximo tolerável ou do número máximo de ciclos de treinamento.

Função de ativação

Nas Equações 2.10 e 2.11 são apresentadas, respectivamente, a sigmóide binária (domínio de 0 a 1) e a sigmóide bipolar (domínio de -1 a 1). Estas são duas das funções de ativação mais utilizada em redes com retropropagação do erro [Fausett 1994].

$$f_1(x) = \frac{1}{1 + e^{-x}} \quad (2.10)$$

$$f_2(x) = \frac{2}{1 + e^{-x}} - 1 \quad (2.11)$$

2.2.5.2 Redes LVQ

LVQ (Learning Vector Quantization) é uma técnica de aprendizado supervisionado na qual as informações referentes a uma dada classe são usadas para se mover os pe-

sos dos vetores de referência, melhorando-se as regiões de decisão do classificador [Haykin 1999]. No método LVQ, um conjunto inicial de padrões de treinamento com classificação conhecida deve ser fornecido, juntamente com uma distribuição inicial dos vetores de referência (cada um representando uma dada classificação). Uma vez treinada, a rede LVQ classifica um padrão atribuindo a ele a classe representada pelo vetor de referência que contém as características mais semelhantes ao padrão apresentado.

Arquitetura

Na Figura 2.5 é apresentada a arquitetura básica de uma rede LVQ, sendo:

- $X_i, i = 1, \dots, n$ as unidades da camada de entrada;
- $Y_j, j = 1, \dots, m$ as unidades da camada de saída;
- w_{ij} o peso da conexão entre os neurônios i (entrada) e j (saída).




Figura 2.5: Rede LVQ - Arquitetura [Fausett 1994].

Algoritmo de treinamento

Em uma rede LVQ, um padrão de entrada é apresentado à rede como um vetor de pesos, denominado vetor de entrada. Para a classificação de determinado padrão de entrada, a rede realiza a busca pela unidade de saída que contém o vetor de pesos

mais próximo ao vetor de entrada. Desta forma, durante o treinamento, os pesos das unidades de saída pertencentes à mesma classe do padrão apresentado são movidos em direção ao padrão de entrada. Em contrapartida, os pesos das unidades de saída pertencentes a classes diferentes do padrão apresentado são afastados, i.e. movidos na direção oposta ao padrão de entrada.

O algoritmo de treinamento da rede LVQ pode ser resumido nos seguintes passos [Fausett 1994]:

Sejam:

- x o vetor de entrada $(x_1, \dots, x_i, \dots, x_n)$ denominado também *vetor de treinamento*;
- T a classe correspondente ao vetor de entrada;
- w_j o vetor de pesos da j -ésima unidade de saída $(w_{1j}, \dots, w_{ij}, \dots, w_{nj})$;
- C_j a classe representada pela j -ésima unidade de saída;
- $\|x - w_j\|$ a distância Euclidiana entre o vetor de entrada e o vetor de pesos da j -ésima unidade de saída.

Passo 0: Inicialização (unidades de saída e taxa de aprendizagem).

Passo 1: Enquanto a condição de parada for falsa, execute os passos 2-6.

Passo 2: Para cada padrão de treinamento x , execute os passos 3-4.

Passo 3: Determinação do índice j tal que $\|x - w_j\|$ seja mínimo.

Passo 4: Atualização de w_j :

se $T = C_j$ então

$$w_j(\text{novo}) \leftarrow w_j(\text{anterior}) + \alpha(x - w_j(\text{anterior}));$$

senão

$$w_j(\text{novo}) \leftarrow w_j(\text{anterior}) - \alpha(x - w_j(\text{anterior}));$$

Passo 5: Redução da taxa de aprendizagem.

Passo 6: Teste da condição de parada.

Para o caso da rede LVQ, como pode ser observado no algoritmo apresentado, não ocorre a aplicação de uma função de ativação ao padrão de entrada. Como condições de parada, um número máximo de iterações ou um valor suficientemente baixo, atingido pela taxa de aprendizagem, podem ser especificados [Fausett 1994].

2.2.5.3 Redes SOM

Redes de mapas auto-organizáveis (SOM) combinam um princípio de aprendizagem competitiva com um agrupamento topológico de nós no qual nós adjacentes possuem vetores de pesos similares [Mehrotra, Mohan e Ranka 1997]. Durante o treinamento da rede, para um dado padrão de treinamento, o nó com maior ativação e os nós adjacentes a este são aproximados do padrão apresentado. Desta forma, ainda que a inicialização dos vetores de pesos seja aleatória, as redes são auto-organizáveis, uma vez que as unidades de classificação são deslocadas de modo a capturar as características essenciais dos padrões de entrada utilizados no treinamento. Dentre as diversas aplicações das redes SOM, pode-se citar pré-processamento e classificação de sinais e imagens [Kohonen 1990, Kiso e Seki 2010].

Arquitetura

A arquitetura de uma rede SOM é essencialmente a mesma de uma rede LVQ, como apresentado na Figura 2.5. No entanto, para o caso da rede SOM, uma estrutura topológica é assumida pelos neurônios da camada de saída. Além disso, na rede SOM, não se sabe inicialmente qual neurônio de saída representa cada classe, uma vez que esta rede utiliza um método de aprendizagem não supervisionada [Fausett 1994].

Algoritmo de treinamento

O algoritmo de treinamento de uma rede SOM pode ser descrito pelos passos a seguir [Fausett 1994]:

Passo 0: Inicialização dos pesos w_{ij} , parâmetros de vizinhança e da taxa de aprendizagem.

Passo 1: Enquanto a condição de parada for falsa, execute os passos 2-8.

Passo 2: Para cada padrão de treinamento x , execute os passos 3-5.

Passo 3: Para cada j , calcule:

$$D(j) = \sum_i (w_{ij} - x_i)^2.$$

Passo 4: Encontre o índice J tal que $D(J)$ é um mínimo.

Passo 5: Para todas unidades j pertencentes a uma vizinhança

específica de J e para todo i :

$$w_{ij}(\text{novo}) = w_{ij}(\text{anterior}) + \alpha[x_i - w_{ij}(\text{anterior})].$$

Passo 6: Atualização da taxa de aprendizagem.

Passo 7: Atualização dos parâmetros de vizinhança.

Passo 8: Teste da condição de parada.

Como no caso da rede LVQ, é possível observar que, para a rede SOM, não ocorre a aplicação de uma função de ativação específica ao padrão de treinamento.

No Quadro 2.1 é apresentado um breve resumo com algumas características das redes neurais artificiais descritas anteriormente. Maiores detalhes sobre estas redes podem ser encontrados nos trabalhos de Fausett [Fausett 1994], Mehrotra [Mehrotra, Mohan e Ranka 1997], Haykin [Haykin 1999] e Kohonen [Kohonen 2001].

Quadro 2.1: Resumo comparativo das redes neurais artificiais apresentadas

Rede	Arquitetura	Treinamento	Método de aprendizagem	Aplicações
MLP	1 camada de entrada; 1 camada de saída; 1 ou mais camadas intermediárias	Supervisionado	Retropropagação do erro (gradiente descendente)	Classificação de padrões, regressão não linear e mineração de dados.
LVQ	1 camada de entrada; 1 camada de saída	Supervisionado	Aprendizagem competitiva	Classificação ou reconhecimento de padrões.
SOM	Mapa topográfico com 1 camada de entrada e 1 camada de saída	Não supervisionado	Aprendizagem competitiva	Pré-processamento e classificação de padrões.

Para este trabalho, foram realizados testes com as redes MLP e LVQ, pois estas possuem vasta aplicação na classificação de padrões em treinamento supervisionado [Haykin 1999]. A aplicação destas redes na classificação de outros tipos de sinais tem sido investigada por alguns pesquisadores nos últimos anos [He et al. 2006, Wang et al. 2009, Janghel et al. 2010, Kashtiban, Razmi e Kozehkonan 2011]. Os resultados dos testes realizados neste trabalho são apresentados no Capítulo 6.

2.3 Fundamentos de Realidade Virtual

A Realidade Virtual pode ser definida como uma “interface avançada do usuário” para acessar aplicações executadas no computador, tendo como características a visualização de, e movimentação em, ambientes tridimensionais em tempo real e a interação com elementos desse ambiente [Tori e Kirner 2006]. Em outras palavras, a Realidade Virtual é uma tecnologia que convence o usuário (participante do ambiente virtual) de estar em outro lugar pela substituição dos estímulos sensoriais primários do participante por dados recebidos de um computador [Yoh 2001, Heim 2000].

Sistemas de Realidade Virtual têm sido utilizados nas mais diversas áreas do conhecimento. Alguns domínios de aplicação incluem as indústrias de petróleo e gás, fabricação de carros e aeronaves, aplicações militares, educação, publicidade e propaganda [Cardoso e Lamounier 2006, Sordi e Valdambrini 2006, Qiu e Chen 2009, Lima, Cunha e Landau 2010].

Além das aplicações citadas anteriormente, a Realidade Virtual vem sendo utilizada já há alguns anos nas ciências médicas, abrindo várias possibilidades no que se refere ao tratamento de diversos distúrbios e patologias humanas [Burdea 2002, Costa e Ribeiro 2009]. Dentre as aplicações de Realidade Virtual nestas áreas pode-se citar o tratamento de fobias e os ambientes virtuais de treinamento voltados à reabilitação humana [Batteau et al. 2004, Nunes et al. 2007, Brinkman, Sandino e Mast 2009, Bruce e Regenbrecht 2009]. Nas próximas seções, serão apresentadas algumas aplicações de Realidade Virtual na medicina, psicologia e outras áreas relacionadas à saúde humana.

2.3.1 Ambientes virtuais utilizados em reabilitação

A Realidade Virtual, quando aplicada à reabilitação humana, possibilita a criação de ambientes nos quais a intensidade do treinamento pode ser, sistematicamente, manipulada de modo a adaptar o ambiente virtual de reabilitação às necessidades de cada paciente [Jack et al. 2001]. Para tal, os pacientes são convidados a executar, em um ambiente virtual, uma série de exercícios determinada pelo profissional de saúde responsável (médico, psicólogo ou terapeuta). A comunicação do paciente com o ambiente virtual é feita através de dispositivos específicos de entrada/saída,

tais como dispositivos hápticos, monitores HMD, dentre outros. Por fim, sistemas de reabilitação assistidos por computador podem ser integrados a sistemas de bancos de dados, gerando relatórios de treinamento e avaliações estatísticas das sessões de treinamento, além de proporcionar ao médico ou terapeuta a possibilidade de acompanhar em tempo real ou posteriormente o desempenho do paciente na execução dos exercícios propostos [Mattioli et al. 2011].

A Figura 2.6 apresenta uma plataforma de reabilitação para pacientes que sofreram acidente vascular cerebral (AVC). O sistema, denominado SAIL (*Stimulation Assistance through Iterative Learning*), apresenta ao paciente uma série de exercícios de posicionamento de objetos em um ambiente virtual tridimensional. Os exercícios são customizados pelo fisioterapeuta, de acordo com as necessidades e a evolução de cada paciente [Cai et al. 2011].



Figura 2.6: Paciente utilizando o sistema SAIL [Cai et al. 2011]

Nas Figuras 2.7(a) e 2.7(b) são apresentados os dois exercícios de coordenação que compõem o sistema de reabilitação ortopédica proposto por Popescu [Popescu et al. 2000]: *peg board* 2.7(a) e arremesso/captura de bola 2.7(b). Neste sistema, uma arquitetura cliente-servidor permite que o paciente realize os exercícios em casa enquanto o terapeuta acompanha remotamente o desenvolvimento do paciente [Po-

pescu et al. 2000].




Figura 2.7: Exercícios: (a) *Peg board*. (b) Arremesso/captura de bola [Popescu et al. 2000].

2.4 Considerações finais

Neste capítulo, foram apresentados alguns dos fundamentos de Engenharia Biomédica e de Redes Neurais Artificiais associados ao desenvolvimento e construção de próteses de mão. Dentre os tópicos abordados, estão técnicas de controle de membros artificiais, processamento digital de sinais EMG e classificação de sinais biomédicos. Foram abordados também alguns dos fundamentos de Realidade Virtual aplicados às áreas médicas. Dentre as diversas aplicações, destacam-se os ambientes de treinamento, tratamento de fobias e de reabilitação. No próximo capítulo será apresentado um estudo de alguns trabalhos correlatos ao tema desta dissertação.

Capítulo 3

Trabalhos Correlatos

3.1 Introdução

Visando analisar o estado da arte dos sistemas de simulação de próteses utilizando Realidade Virtual realizou-se um levantamento de alguns trabalhos correlatos, procurando avaliar sua aplicabilidade, suas limitações e perspectivas de trabalhos futuros. Neste capítulo, serão discutidos os aspectos de maior relevância abordados nestes trabalhos.

3.2 Reconhecimento de padrões EMG em tempo real

Para o caso de próteses mioelétricas, o processamento do sinal EMG foi discutido em diversos trabalhos tais como Chu *et al.* [Chu, Moon e Mun 2006] e Herle *et al.* [Herle et al. 2008]. Em Chu *et al.* [Chu, Moon e Mun 2006], é apresentada uma técnica de reconhecimento de padrões composta por 3 etapas fundamentais, apresentadas na Figura 3.1.




Figura 3.1: Reconhecimento de padrões EMG [Chu, Moon e Mun 2006].

Inicialmente, um vetor de características é extraído de uma janela de 250 ms do sinal EMG, utilizando a transformada *wavelet packet*. Maiores detalhes sobre a aplicação desta transformada a sinais EMG podem ser encontrados no trabalho de Englehart [Englehart, Hudgin e Parker 2001].

Em seguida, é realizada a redução dimensional e a projeção de características utilizando análise de componente principal (*principal component analysis* - PCA) e mapas auto-organizáveis de características (*self-organizing feature map* - SOFM). Em linhas gerais, esta etapa tem como função simplificar a estrutura do classificador (melhorando a separabilidade dos padrões) e reduzir o tempo de processamento (pela redução dimensional dos padrões).

Finalmente, é realizada a classificação do movimento por uma rede de perceptrons multicamada (MLP).

Neste trabalho, foram contemplados 9 movimentos diferentes da mão, capturados por 4 canais EMG: flexão/extensão do pulso, desvio ulnar/radial do pulso, pronação/-supinação do pulso, abertura/fechamento da mão e posição de relaxação (repouso). Os experimentos realizados indicaram um tempo de resposta inferior a 125 ms, desde o janelamento do sinal até a movimentação da mão virtual. No entanto, para o janelamento dos sinais, foi utilizada uma janela móvel de comprimento 250 ms e incremento igual a 125 ms. Desta forma, a diferenciação entre sinal e ruído só ocorre após a extração das características do sinal, uma vez que a janela móvel é deslocada tanto na realização de determinado movimento como na posição de repouso. Esta estratégia requer maior quantidade de processamento na discriminação dos movimentos, o que pode ser uma limitação na portabilidade deste sistema para um microcontrolador miniaturizado, por exemplo, uma prótese real.

3.3 Controle em tempo real de uma mão virtual

O sistema de controle utilizado nas próteses também tem sido pesquisado e discutido em diversos trabalhos, tais como Sebelius *et al.* [Sebelius *et al.* 2005], Craelius *et al.* [Craelius, Abboudi e Newby 1999] e Pons *et al.* [Pons *et al.* 2005]. Sebelius *et al.* [Sebelius *et al.* 2005] avaliaram a performance de um sistema de controle mioelétrico de próteses utilizando uma mão virtual.

Para o treinamento do sistema, diferentes posições dos dedos foram capturadas pelos sensores de uma luva de dados e associados aos respectivos sinais EMG. Para o caso de pacientes com amputação de uma mão, a luva de dados foi posicionada na mão oposta, e os movimentos realizados simultaneamente nas duas mãos. O reconhecimento de padrões foi feito utilizando um algoritmo de *lazy learning*, baseado no algoritmo *K-nearest neighbors* (KNN) [Atkeson, Moore e Schaal 1997, Hattori e Takahashi 1999]. Para se determinar o padrão vizinho mais próximo, foi utilizada a distância euclidiana mínima. Maiores detalhes dessa implementação podem ser encontrados em Sebelius *et al.* [Sebelius et al. 2005] e Atkeson *et al.* [Atkeson, Moore e Schaal 1997].

A utilização da luva de dados para auxiliar o processo de calibração, fornecendo dados de referência mais precisos ao classificador, possibilitou melhorias na performance global do sistema de classificação. Dada a simplicidade do sistema de controle, este pode ser implementado sem maiores dificuldades em *hardwares* miniaturizados. Entretanto, a presença da luva de dados no processo de calibração restringe a utilização do sistema a pacientes que possuam pelo menos uma mão saudável. A avaliação da performance de outras técnicas de classificação, como por exemplo as redes MLP ou LVQ, também não foi contemplada no escopo deste trabalho.

3.4 Prótese MANUS

No trabalho desenvolvido por Pons *et al.* [Pons et al. 2005], foi implementada uma linguagem de comando para próteses mioelétricas de mão. Com a finalidade de se testar a linguagem implementada, foi utilizado um processo de treinamento baseado em Realidade Virtual. A Figura 3.2 apresenta um usuário da prótese MANUS.

A linguagem de comando desenvolvida neste projeto para a prótese MANUS consiste em uma linguagem de comando digitalmente codificada. O usuário da prótese realiza sucessivas contrações de determinado músculo. De acordo com limiares pré-estabelecidos, cada contração pode ser classificada em três diferentes níveis: “0”, “1” ou “2”. Uma vez reconhecida a palavra de comando (uma sequência de contrações reconhecidas pelo sistema), a prótese realiza o movimento correspondente à palavra de comando. A Figura 3.3 apresenta um exemplo de palavra de comando. No exemplo



Figura 3.2: Usuário da prótese MANUS [Pons et al. 2005].

apresentado, as 3 contrações consecutivas formam a palavra “121”, de acordo com os limiares A_1 e A_2 .




Figura 3.3: Palavra de comando da prótese MANUS. [Pons et al. 2005].

Na Figura 3.4 é apresentado o ambiente de treinamento em RV de usuários da prótese MANUS.

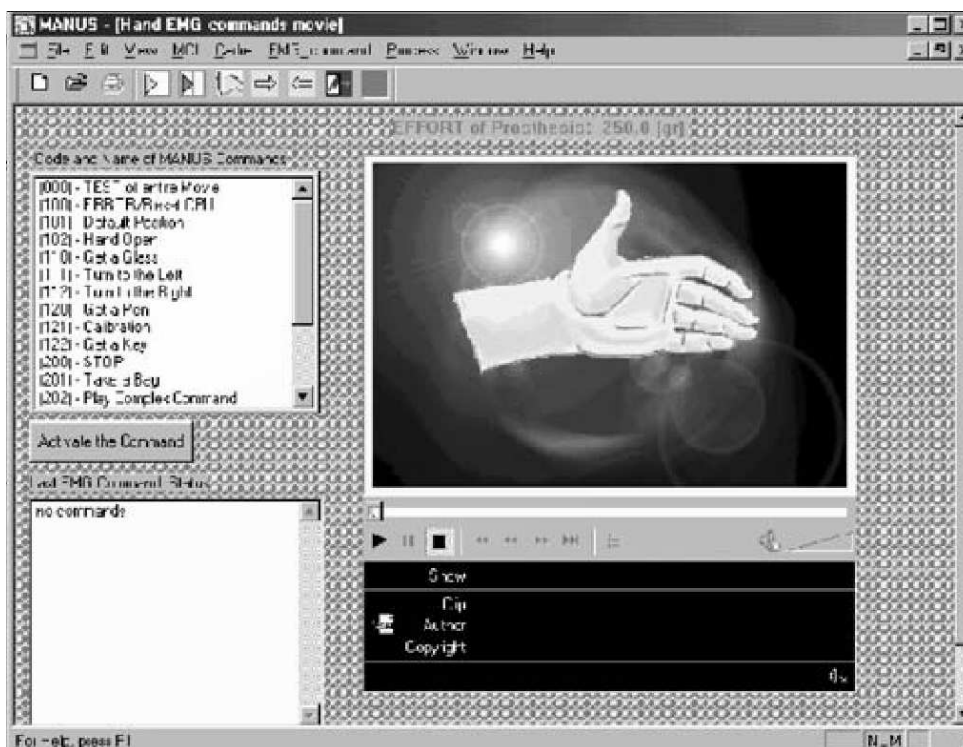


Figura 3.4: Ambiente virtual de treinamento [Pons et al. 2005].

Uma vez que o controle do membro artificial é feito a partir de uma linguagem binária de comando, este sistema possui maior flexibilidade com relação às posturas e movimentos executado pela prótese. Além disso, a detecção dos comandos se dá de forma simples, pois cada comando é composto por uma sequência de contrações musculares de duração variável. Contudo, ainda que o controle por linguagem de comando possa ser facilmente assimilado pelos pacientes, este não representa uma forma natural de controle dos membros, especialmente para pacientes que sofreram alguma forma de amputação. Além disso, o janelamento utilizado neste trabalho baseia-se em funções de decisão configuradas a partir de dados estatísticos. Esta abordagem pode apresentar limitações no que se refere à capacidade de generalização do sistema de classificação (resposta do sistema a dados similares aos dados de treinamento, porém desconhecidos).

3.5 Classificação de sinais EMG utilizando características no domínio do tempo

Herle *et al.* [Herle et al. 2008] apresentam uma técnica de classificação de sinais EMG baseada em características no domínio do tempo e em redes neurais artificiais. A aplicação da técnica de classificação proposta é avaliada em um sistema de auxílio a usuários de próteses mioelétricas na fase de treinamento. A Figura 3.5 apresenta a arquitetura deste sistema.

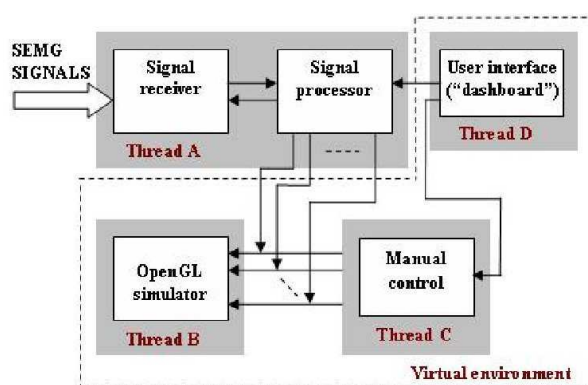


Figura 3.5: Arquitetura do sistema [Herle et al. 2008]

Os sinais EMG foram coletados em 2 canais, com os respectivos eletrodos posicionados no bíceps e no tríceps dos pacientes. 5 características no domínio do tempo foram extraídas: MAV, MAVS, ZC, SSC e WL (a seção 2.2.4.2 apresenta uma explicação mais detalhada destas 5 características). A classificação dos movimentos foi feita utilizando uma rede MLP. Finalmente, o movimento classificado é reproduzido por uma prótese virtual, apresentada na Figura 3.6.

O sistema abordado neste trabalho apresenta uma boa performance do classificador (acima de 96%) utilizando características no domínio do tempo. A principal vantagem das características utilizadas está na simplicidade de implementação, pois estas podem ser implementadas com operações aritméticas simples (soma, subtração, divisão), comparadores e contadores. No entanto, dentro do escopo deste trabalho, não foram investigados os movimentos da mão nem a performance do sistema em tempo real. A influência de cada uma das 5 características na performance global de classificação também não foi abordada neste trabalho.




Figura 3.6: Prótese virtual [Herle et al. 2008]

3.6 RV e RA aplicados à simulação de próteses de membros superiores

Finalmente, no trabalho desenvolvido por Nogueira [Nogueira 2007] é apresentada a arquitetura de um sistema que permite a visualização de próteses de membros superiores em Realidade Virtual e Realidade Aumentada. O sistema utiliza sinais EMG para controle das próteses e possibilita a coleta e o processamento dos dados em tempo de execução. A Figura 3.7 apresenta a arquitetura deste sistema.

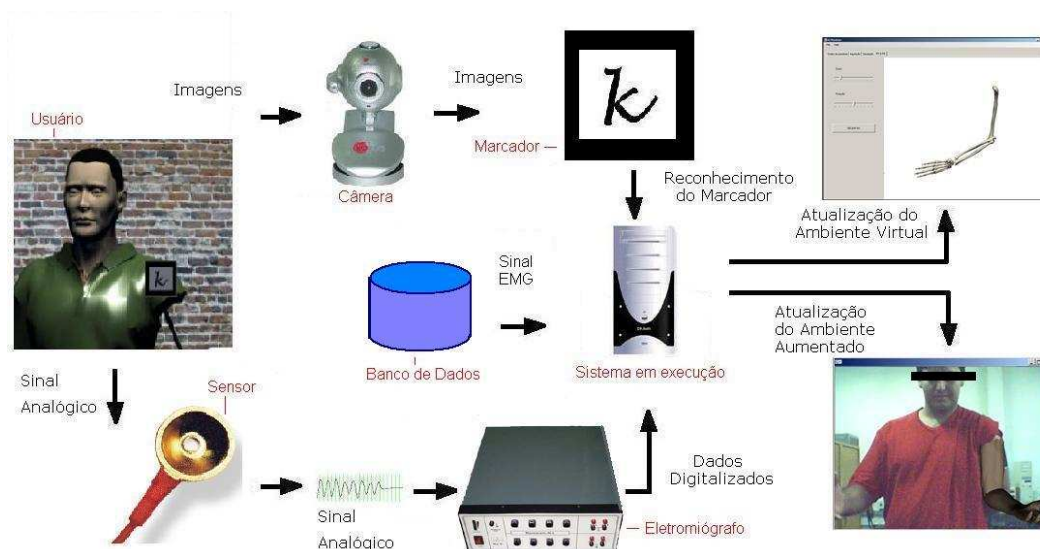


Figura 3.7: Arquitetura do sistema [Nogueira 2007]

Para a classificação dos movimentos, foi utilizado o modelo auto-regressivo e uma

rede neural artificial treinada com retropropagação do erro, como apresentado em Andrade [Andrade 2000] e Lamounier *et al.* [Lamounier et al. 2010]. O grande diferencial deste trabalho está na possibilidade de utilização de Realidade Aumentada durante o treinamento, tal como apresentado na Figura 3.8.



Figura 3.8: Ambiente em Realidade Aumentada [Nogueira 2007].

O trabalho discutido nesta seção apresenta como diferenciais a simulação da prótese em Realidade Aumentada e a comunicação do ambiente de treinamento com um sistema de banco de dados. Contudo, no âmbito deste trabalho não foram contemplados os movimentos da mão. A performance de outras redes neurais (por exemplo, LVQ) na classificação dos movimentos apresentados e a utilização de outras técnicas de janelamento (diferentes do janelamento fixo por amplitude do sinal) também não foram discutidos.

3.7 Resumo comparativo dos trabalhos analisados

Na Tabela 3.1 é apresentado um resumo das características dos trabalhos correlatos, analisados neste capítulo. O Quadro 3.2 apresenta uma comparação destes, desta-

cando os elementos que motivaram o presente estudo (vide Capítulo 4). Observando o escopo e as técnicas abordadas em cada um destes trabalhos, foram escolhidos como parâmetros de comparação os elementos de maior impacto na performance de classificação e na usabilidade dos sistemas apresentados. São eles:

- *Movimentos investigados*: neste item, foram analisados os movimentos contemplados em cada trabalho.
- *Janelamento*: refere-se à forma como o sistema diferencia informações relevantes (movimentos) de ruídos (estado de repouso). Alguns sistemas realizam a extração de características dos ruídos e, pelo mecanismo de classificação, detectam o estado de repouso. Em outros sistemas, ocorre a detecção (manual ou automática) dos intervalos com informações relevantes (janelamento), descartando-se os intervalos que contenham apenas ruídos.
- *Tipo de pré-processamento*: neste item, foram analisadas as diferentes abordagens de pré-processamento dos sinais EMG.
- *Classificador*: refere-se ao tipo de classificador utilizado para discriminar os diferentes movimentos.
- *Performance em tempo real*: refere-se à avaliação da aplicabilidade dos algoritmos apresentados em sistemas de tempo real.
- *Realidade Virtual*: refere-se à utilização de Realidade Virtual como mecanismo de *feedback* relacionado aos movimentos realizados.

3.8 Considerações finais

Neste capítulo, foram apresentados os principais elementos de alguns trabalhos correlatos ao tema desta dissertação. As principais limitações dos sistemas abordados estão relacionadas aos movimentos considerados, ao tipo de janelamento realizado, à investigação da performance de diferentes classificadores, à avaliação do desempenho em tempo real destes sistemas e à utilização de Realidade Virtual como mecanismo de *feedback*. A partir das limitações observadas, foi realizada a especificação do sistema proposto no presente trabalho, apresentada no próximo capítulo.

Tabela 3.1: Características dos trabalhos correlatos

Trabalho	Movimentos	Janelamento	Pré-processamento	Classificador	Tempo real	Realidade Virtual
Chu, 2006	Mão/pulso	Fixo (250 ms)	Wavelet/PCA/SOFM	MLP	Sim	Sim
Sebelius, 2005	Dedos/pulso	Fixo (50 ms)	Filtro de envoltória linear	<i>Lazy learning</i>	Sim	Sim
Pons, 2005	Mão/pulso	^a	Não possui	^b	Sim	Sim
Herle, 2008	Braço	Fixo (200 ms)	Características no domínio do tempo	MLP	Não	Sim
Nogueira, 2007	Braço	Fixo (200 ms)	Coeficientes auto-regressivos	MLP	Simulação	Sim

^aO janelamento utiliza funções de decisão parametrizadas por dados estatísticos^bO classificador compara os valores de pico da contração com os limiares pré-definidos

Quadro 3.2: Resumo comparativo dos trabalhos correlatos

Trabalhos relacionados	Movimentos da mão	Janelamento por TKEO	Características no domínio do tempo	Classificador LVQ	Teste de performance em tempo real
Chu, 2006	✓	✗	✗	✗	✓
Sebelius, 2005	✓	✗	✗	✗	✓
Pons, 2005	✓	✗	✗	✗	✓
Herle, 2008	✗	✗	✓	✗	✗
Nogueira, 2007	✗	✗	✗	✗	✓

Capítulo 4

Especificação do sistema proposto

4.1 Introdução

Após o estudo comparativo dos trabalhos correlatos apresentados no Capítulo 3, foi definido o escopo deste trabalho, resumido a seguir:

- *Movimentos*: neste trabalho foram avaliados os movimentos de flexão dos dedos da mão e de flexão/extensão/pronação do pulso. Estes movimentos estão presentes, com pequenas variações, nos trabalhos correlatos cujo escopo inclui os movimentos da mão;
- *Janelamento*: quando se realiza o janelamento de comprimento fixo, como apresentado em alguns dos trabalhos correlatos, deve-se utilizar um mecanismo auxiliar de discriminação sinal/ruído. Este mecanismo pode resultar em um aumento significativo na quantidade de processamento necessária à classificação dos movimentos abordados. Este aumento se deve à necessidade de realizar o pré-processamento contínuo do sinal de entrada, mesmo estando o músculo de comando em repouso. Visando investigar a performance de uma técnica dinâmica de janelamento dos sinais, neste trabalho foi utilizado um algoritmo de janelamento automático, baseado no operador TKEO (*Teager-Kaiser energy operator* - vide seção 5.6.1). Neste algoritmo, a discriminação sinal/ruído é realizada antes da extração de características, que só será aplicada aos intervalos do sinal de entrada que representem atividade muscular (intervalos de repouso não são pré-processados, reduzindo a carga de processamento do sistema);

- *Pré-processamento*: para o pré-processamento, foram utilizadas as mesmas características no domínio do tempo apresentadas por Herle *et al.* [Herle et al. 2008], na classificação dos movimentos do braço. No entanto, neste trabalho, foi realizada uma avaliação quantitativa do impacto de cada característica no desempenho global do classificador. Os resultados desta avaliação são apresentados no Capítulo 6;
- *Classificador*: visando avaliar o desempenho de diferentes mecanismos de classificação, neste trabalho foram realizados testes com 2 redes neurais artificiais - uma rede LVQ (vide seção 2.2.5.2) e uma rede MLP (vide seção 2.2.5.1). Os resultados destes testes são apresentados também no Capítulo 6;
- *Tempo real*: para avaliar a performance do sistema em uma aplicação em tempo real, foi construído um simulador, apresentado na seção 5.6.
- *Realidade Virtual*: um braço artificial foi adaptado a um ambiente de Realidade Virtual para proporcionar o *feedback* visual relacionado aos movimentos abordados. Este ambiente é discutido na seção 5.5.

Neste capítulo, serão discutidos os principais requisitos do protótipo desenvolvido no presente trabalho. Primeiramente, serão apresentados os requisitos funcionais (funcionalidades) e não funcionais (requisitos de desempenho e resposta) do sistema proposto. Em seguida, serão apresentados os principais requisitos de performance em tempo real. Ao final do capítulo, são apresentados os diagramas de casos de uso e o diagrama de classes referentes ao sistema proposto.

4.2 Requisitos funcionais

Os principais requisitos funcionais de um sistema em RV para o treinamento de usuários de próteses envolvem a correta classificação dos movimentos realizados pela prótese, a configuração dos parâmetros do classificador e o controle do ambiente virtual de treinamento.

4.2.1 Configuração dos parâmetros do classificador

Com o objetivo de melhorar a performance do classificador, o sistema deve possuir uma interface que permita a configuração dos diversos parâmetros do mesmo. Os parâmetros considerados neste trabalho são:

- Taxa de aprendizagem (*alpha*);
- Decaimento da taxa de aprendizagem (*dec_alpha*);
- Número de unidades de classificação (*n_output_units*);
- Número de classes (*n_classes*);
- Tolerância (*tolerance*).

A definição de cada um destes parâmetros será apresentada na seção 5.4 e sua influência será discutida na seção 6.1.1.

4.2.2 Teste do classificador

Para que o usuário possa testar o classificador, o sistema deve possibilitar que um sinal de teste seja processado e classificado pelo sistema. É desejável ainda que o sistema realize a classificação de diversos sinais, procedendo posteriormente a uma avaliação estatística dos resultados obtidos nesta classificação.

4.2.3 Controle do ambiente virtual

O ambiente virtual desempenha um importante papel no contexto da aplicação proposta. É o ambiente virtual que atuará como canal de comunicação entre o sistema e o paciente, fornecendo o *feedback* visual necessário para o treinamento deste. Assim sendo, deve ser concebida uma arquitetura que possibilite a manipulação de uma prótese virtual a partir dos movimentos detectados pelo classificador.

4.3 Requisitos não funcionais

Os principais requisitos não funcionais do sistema em questão estão relacionados à performance de classificação dos movimentos abordados, à resposta em tempo real do sistema e à qualidade da simulação realizada.

4.3.1 Classificação dos movimentos

Uma vez que a aplicação principal do sistema proposto neste trabalho é o treinamento de usuários em potencial de próteses mioelétricas, é de fundamental importância que o classificador atinja altos níveis de desempenho na classificação dos movimentos abordados. Tendo em vista a aplicabilidade do sistema proposto na avaliação da aptidão de pacientes em controlar próteses mioelétricas, erros no classificador podem levar a um diagnóstico equivocado desta aptidão, resultando em sérios riscos à integridade física do paciente e ao equipamento.

Em alguns trabalhos correlatos, tais como Herle *et al.* [Herle et al. 2008], Lamounier *et al.* [Lamounier et al. 2010] e Soares *et al.* [Soares et al. 2003] são reportadas performances de classificação superiores a 90% (chegando a 100% em alguns casos). Desta forma, para este trabalho, foi admitido como requisito de performance de classificação o mínimo de 90% dos padrões de teste corretamente classificados. Mais detalhes a respeito do cálculo da performance de classificação são apresentados na seção 6.1.

4.3.2 Tempo de resposta

De acordo com Chu *et al.* [Chu, Moon e Mun 2006], Englehart e Hudgins [Englehart e Hudgins 2003], o tempo de resposta de um sistema de controle para próteses mioelétricas de mão não deve ultrapassar 300 ms. Uma vez que o presente trabalho objetiva desenvolver um ambiente virtual de treinamento que simule o comportamento de uma prótese, é importante que este atraso seja respeitado também no ambiente virtual. Desta forma, adotou-se como requisito para este trabalho que o classificador deve ter um tempo de resposta inferior a 200 ms, tendo em vista o atraso entre a classificação do sinal e a execução do movimento correspondente no ambiente virtual. Este valor

foi determinado após verificar-se, experimentalmente, que a comunicação entre o sistema de classificação e o ambiente virtual ocorre em menos de 100 ms, o que leva a um atraso máximo de 300 ms entre a execução do movimento e a movimentação da prótese virtual.

4.3.3 Simulação realística

Tendo em vista que o sistema proposto neste trabalho possui aplicação no treinamento de usuários de próteses de mão, é de extrema importância que o ambiente virtual que simula a prótese proporcione um alto grau de realismo, de modo a facilitar a imersão do usuário no ambiente de treinamento. Como reportado por Herle *et al.* [Herle et al. 2008] e Nogueira [Nogueira 2007], as dificuldades encontradas durante o treinamento, tais como a adaptação ao controle dos dispositivos e o grande esforço mental empregado nesta fase, acabam resultando em um alto índice de desistência por parte dos pacientes. Desta forma, muitos destes optam por utilizar próteses mecânicas ou mesmo próteses puramente estéticas. Sendo assim, o ambiente virtual de treinamento deve ser simples e ao mesmo tempo oferecer um certo grau de interação e sensação de presença ao paciente, por meio da simulação realística da prótese ou do membro virtual.

4.4 Requisitos de performance em tempo real

O sistema proposto neste trabalho deverá ser capaz de realizar o processamento de sinais EMG referentes aos 4 movimentos da mão considerados: flexão, extensão e pronação do pulso e flexão dos dedos. No entanto, é necessário garantir que a resposta do sistema ocorra dentro de limites operacionais desejáveis, respeitando as restrições temporais da aplicação (resposta em tempo real). Para tal, o sistema deve possuir, essencialmente, um módulo de aquisição de dados e um algoritmo de janelamento que respeitem estas mesmas restrições temporais. O módulo de aquisição de dados deve coletar e enviar dados ao sistema de classificação, sem acrescentar atrasos consideráveis e garantindo a integridade da informação enviada. O algoritmo de janelamento, por sua vez, é responsável por determinar quais intervalos dos sinais recebidos realmente possuem informações relevantes ao controle da prótese virtual.

4.4.1 Aquisição de dados

No controle de próteses EMG um sistema de aquisição monitora constantemente o estado dos músculos que participam dos movimentos desejados. Desta forma, em uma aplicação que simule uma prótese, é necessário que se capture e armazene os sinais dos músculos, para que estes sejam processados e discriminados pelo classificador. Portanto, é necessário que o sistema possua um mecanismo de armazenamento temporário dos sinais coletados, que funcionará como a interface entre o sistema de aquisição e o sistema de classificação.

4.4.2 Janelamento dos sinais

Uma das atividades mais importantes do sistema de classificação é a discriminação entre sinal e ruído. Em outras palavras, é de suma importância que o sistema de classificação possa detectar os intervalos do sinal que contém atividade muscular e, conseqüentemente, informações relevantes à classificação. Esta detecção afeta diretamente a performance de classificação, uma vez que a correta detecção dos intervalos de atividade muscular reduz a quantidade de informações a serem processadas pelo classificador. Sendo assim, intervalos que não contém informações relevantes podem ser ignorados pelos sistemas de pré-processamento e classificação, o que restringe a atuação destes sistemas a intervalos de atividade muscular.

4.5 Diagramas de casos de uso

Nesta seção serão apresentados os principais diagramas de casos de uso do protótipo desenvolvido. Os diagramas apresentados (em linguagem UML- *Unified Modeling Language*) foram concebidos de acordo com as recomendações apresentadas por Ambler [Ambler 2002] e Fowler [Fowler 2004].

4.5.1 Tratamento dos dados

- *Formatar arquivos de dados*: visando aumentar a compatibilidade do sistema, os arquivos de dados devem ser convertidos para um formato padrão. Neste

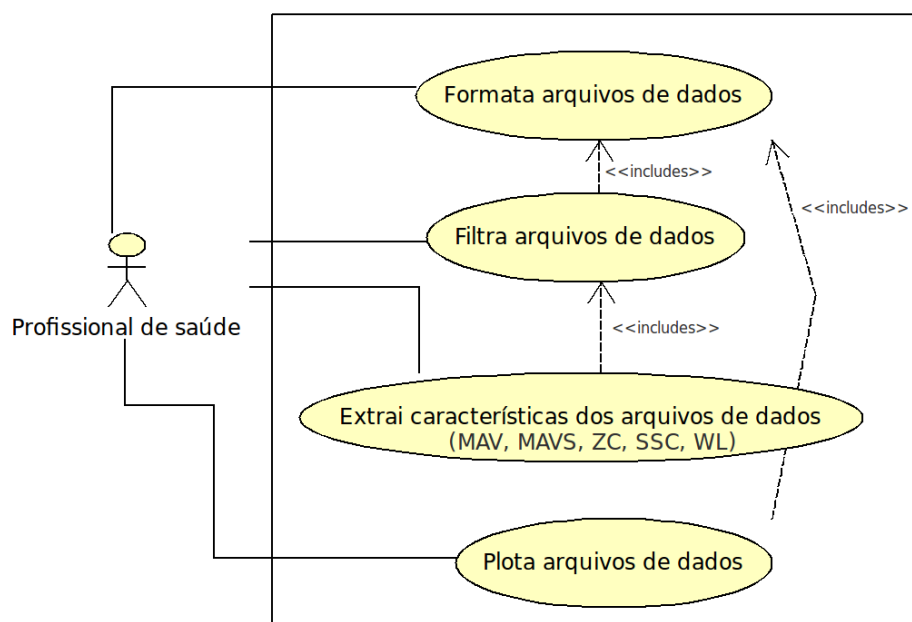


Figura 4.1: Casos de uso: tratamento dos dados.

formato, o arquivo de dados é formado por um conjunto de linhas e cada linha contém a amplitude normalizada do sinal EMG em determinado instante de tempo. A Figura 4.2 apresenta, como exemplo, parte de um arquivo de dados já formatado.

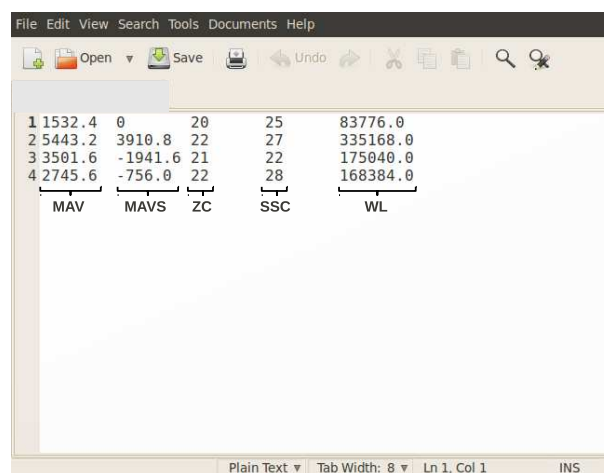
Instante de tempo	Amplitude do sinal
18 390	-2112
19 391	448
20 392	2864
21 393	-1264
22 394	704
23 395	-2096
24 396	304
25 397	2704
26 398	-608
27 399	48
28 400	-1888
29 401	992
30 402	2592
31 403	-1312
32 404	80
33 405	-768
34 406	304
35 407	3152
36 408	-1072

Figura 4.2: Exemplo de arquivo de dados.

- *Filtrar arquivos de dados*: o usuário deve ser capaz de filtrar os arquivos de dados previamente formatados, para separar os intervalos de tempo que contém informações relevantes das demais amostras contidas no arquivo. O filtro con-

siste no janelamento (segmentação) do sinal nos intervalos obtidos a partir da aplicação da técnica descrita na seção 5.6.1.

- *Extrair características dos arquivos de dados:* um sistema de extração de características deve ser implementado com o objetivo de se otimizar o treinamento do classificador. Após a extração das características dos padrões de treinamento, os vetores de características devem ser armazenados em disco, para sua posterior utilização no treinamento do classificador. A Figura 4.3 apresenta, como exemplo, alguns vetores de características extraídos de um arquivo de dados.



1	1532.4	0	20	25	83776.0
2	5443.2	3910.8	22	27	335168.0
3	3501.6	-1941.6	21	22	175040.0
4	2745.6	-756.0	22	28	168384.0
	MAV	MAVS	ZC	SSC	WL

Figura 4.3: Exemplos de vetores de características: *Mean Absolute Value* - MAV, *Mean Absolute Value Slope* - MAVS, *Zero Crossing* - ZC, *Slope Sign Changes* - SSC e *Waveform Length* - WL.

- *Plotar arquivos de dados:* cada sinal armazenado em disco deve estar associado ao seu respectivo gráfico, que deverá ser plotado e armazenado na base de dados.

4.5.2 Configuração/teste do classificador

- *Configurar o classificador:* o usuário deve ser capaz de configurar os parâmetros do classificador (apresentados na seção 4.2.1). Esta configuração deve ser realizada facilmente, respeitando os limites operacionais de cada um dos parâmetros.

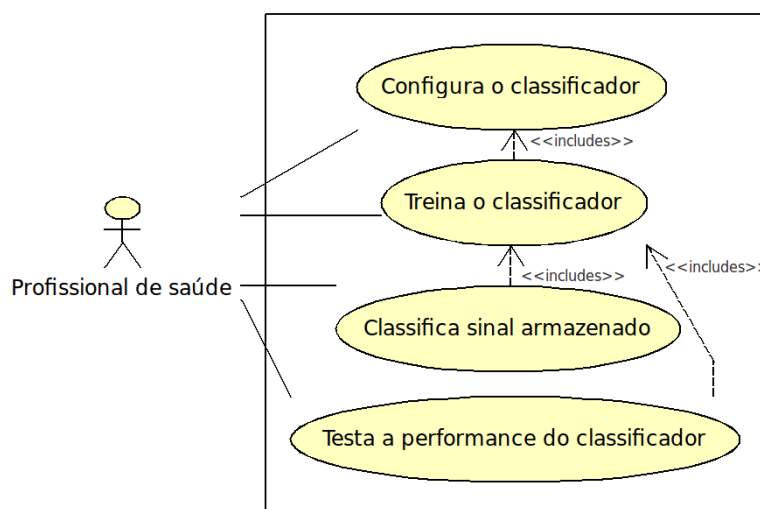


Figura 4.4: Casos de uso: configuração/teste do classificador.

- *Treinar o classificador*: uma vez configurados os parâmetros em questão, o usuário pode treinar o classificador, utilizando para isto um conjunto de padrões armazenados em disco (padrões de treinamento).
- *Classificar sinal armazenado*: com a finalidade de testar o classificador treinado, o usuário pode carregar um dos padrões de treinamento (ou outro padrão que esteja armazenado em disco) e efetuar sua classificação.
- *Testar a performance do classificador*: para se avaliar a performance global do classificador, o usuário pode requerer que este classifique um conjunto de padrões armazenados em disco. Cada padrão deve estar acompanhado de sua classificação correta, para que o sistema avalie as respostas dadas pelo classificador e gere um relatório de performance.

4.5.3 Processamento em tempo real

- *Carregar simulação de tempo real*: Para que o sistema realize a classificação em tempo real de determinado sinal, o usuário deve carregar o simulador com sinais armazenados em disco. O simulador deve então amostrar o sinal carregado e enviar periodicamente as amostras ao sistema de classificação.
- *Visualizar movimento*: uma vez detectado um movimento pelo sistema de classi-

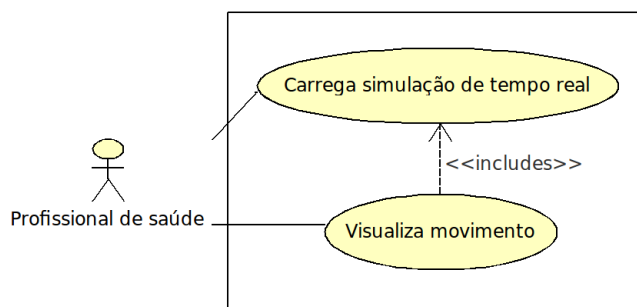


Figura 4.5: Casos de uso: simulação em tempo real.

ficação, ele deve ser reproduzido pelo ambiente virtual para que o usuário tenha o *feedback* visual do movimento correspondente.

4.6 Diagrama de classes

Com base nos requisitos apresentados anteriormente, foi concebida uma primeira estrutura para o protótipo ao qual se refere este trabalho. O diagrama de classes desta estrutura é apresentado na Figura 4.6.

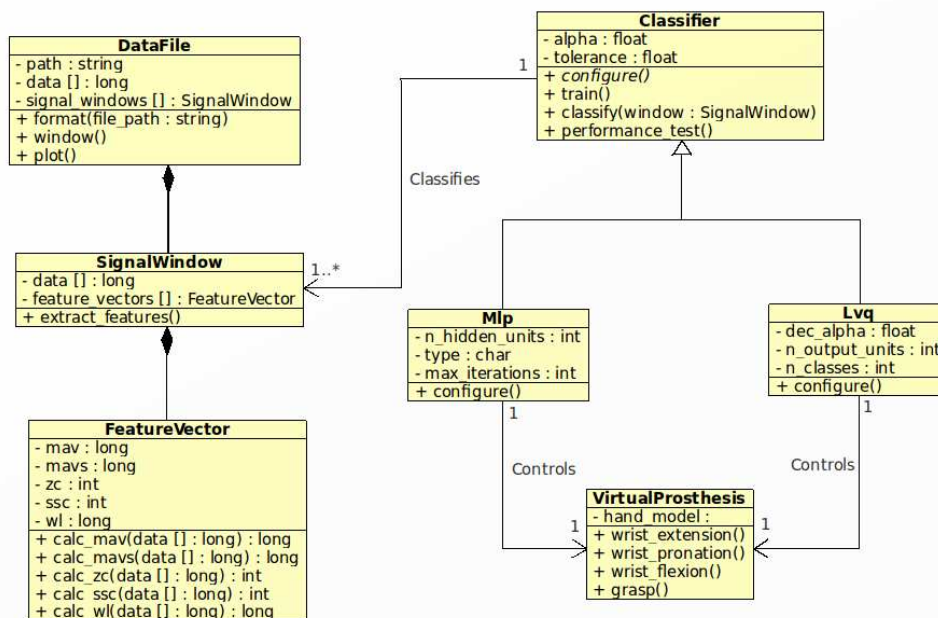


Figura 4.6: Diagrama de classes.

No diagrama apresentado, um arquivo de dados é composto por várias janelas

do sinal (intervalos de tempo que contém informações relevantes). Cada janela de sinal é, por sua vez, dividida em segmentos de tamanho fixo. A cada segmento corresponde um vetor de características. Desta forma, a janela de sinal é composta de um conjunto de vetores de características, contendo as características do movimento correspondente. Por fim, o diagrama apresenta o classificador, que tem a função de classificar as janelas de sinal e controlar a prótese virtual.

4.7 Considerações finais

Neste capítulo, foi apresentada uma breve especificação do sistema proposto, contendo seus principais requisitos e uma primeira estruturação do mesmo. No próximo capítulo, serão apresentados alguns detalhes da implementação, bem como um refinamento da especificação inicial.

Capítulo 5

Detalhes da Implementação

5.1 Introdução

Neste capítulo serão apresentados alguns dos detalhes da implementação do protótipo discutido neste trabalho, desenvolvido de acordo com os requisitos apresentados no Capítulo 4. O protótipo foi implementado na seguinte plataforma de desenvolvimento:

- *Sistema operacional*: Ubuntu Linux 10.04 (Kernel 2.6.32-38).
- *Hardware*: Processador Intel® Core™ 2 Quad 2,33 GHz; 4 GB de memória RAM.
- *Linguagem de programação*: Python 2.6.5, GTK 2.20.1-0
- *Ambiente de modelagem*: Blender 2.49b

5.2 Processo de desenvolvimento

O desenvolvimento do protótipo apresentado teve como diretriz o processo de desenvolvimento de Sistemas de Realidade Virtual (SRV) proposto por Mattioli *et al.* [Mattioli et al. 2009], adequado ao contexto do presente trabalho. Neste processo, uma abordagem iterativa de desenvolvimento é adaptada ao contexto de rápida evolução da tecnologia associada à Realidade Virtual. Além disso, o processo valoriza a importância dos requisitos de interatividade, para projetos desta natureza. O ciclo de vida do processo em questão é apresentado na Figura 5.1.

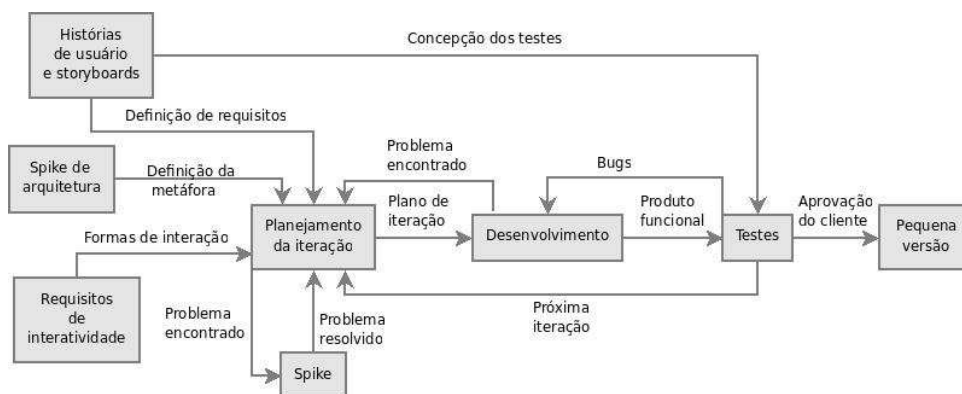


Figura 5.1: Processo de desenvolvimento de SRV [Mattioli et al. 2009].

Na Figura 5.1, é possível notar elementos comuns a alguns processos ágeis [Beck 2004, Hunt 2006], além dos *spikes* de arquitetura e dos requisitos de interatividade.

Nos *spikes* de arquitetura ocorre, essencialmente, a exploração dos recursos disponíveis para a implementação dos requisitos da aplicação. A importância desta abordagem na construção de SRV está na existência de uma etapa dentro do processo de desenvolvimento que permite e incentiva a experimentação, fator de grande importância e constante utilização na modelagem de objetos e cenários virtuais [Mattioli et al. 2009].

A interatividade constitui o elemento central de diversos sistemas de Realidade Virtual, exercendo um papel de fundamental importância na determinação da usabilidade destes sistemas. Sendo assim, a análise detalhada e definição dos requisitos de interatividade, que estão intimamente relacionados à crescente tecnologia em ambientes de RV, ocupa uma posição de destaque dentro do processo de desenvolvimento de SRV [Mattioli et al. 2009].

5.3 Aquisição de sinais

Para desenvolver o presente protótipo, foi necessário utilizar uma base de dados contendo sinais EMG dos 4 movimentos abordados: flexão, extensão e pronação do pulso e flexão dos dedos. A base de dados utilizada possui 5 repetições de cada um dos 4 movimentos, efetuados por 3 indivíduos, totalizando 60 movimentos. Após a segmentação dos sinais, foram obtidos 230 segmentos, utilizados para treinar e testar o

classificador.

A base de dados utilizada foi fornecida pelo laboratório de Engenharia Biomédica da Universidade Federal de Uberlândia ¹. Os dados foram coletados utilizando-se o sistema de aquisição Neuropack MEB-2200 [Kohden 2011], com a seguinte configuração:

- Músculo: flexor radial do carpo
- Frequência de corte inferior: 20 Hz
- Frequência de corte superior: 10 kHz
- Frequência de amostragem: 2 kHz

Um exemplo de sinal da base de dados é apresentado na Figura 5.2.




Figura 5.2: Exemplo de sinal EMG.

5.4 Classificador de sinais

Para classificação dos sinais, foram testados dois classificadores diferentes, ambos baseados em Redes Neurais Artificiais: um classificador LVQ e um classificador MLP [Fausett 1994]. Nesta seção, serão apresentados alguns detalhes de implementação destes classificadores.

¹<http://www.biolab.ufu.br>

5.4.1 Classificador LVQ

A seguir, serão apresentados alguns detalhes de implementação do classificador LVQ, que obteve melhor performance de classificação nos testes realizados neste trabalho.

5.4.1.1 Método de classificação

LVQ é um método de classificação no qual cada unidade de saída (unidade de classificação) representa uma classe ou categoria em particular. Cada unidade de saída possui um vetor de pesos que se refere à classe representada pela unidade. Durante o treinamento, o posicionamento das unidades de saída é otimizado por meio do ajuste dos pesos de cada unidade. Após o treinamento, o classificador LVQ atribui a determinado padrão de entrada a mesma classificação da unidade de saída que possui o vetor de pesos mais próximo ao padrão de entrada [Fausett 1994].

5.4.1.2 Arquitetura

A arquitetura de uma rede LVQ consiste basicamente nas unidades de entrada, nos pesos e nas unidades de saída (unidades de classificação). A arquitetura da rede utilizada neste trabalho é apresentada na Figura 5.3. Nesta figura, x_m representa uma unidade de entrada, y_n representa uma unidade de saída e w_{m_n} representa o peso da unidade de entrada m até a unidade de saída n .




Figura 5.3: Arquitetura da rede LVQ utilizada.

O número de unidades de entrada corresponde ao número de características extraídas de cada padrão. Desta forma, um padrão de entrada é representado por um vetor de características, cuja dimensão é igual ao número de unidades de entrada. Neste trabalho, foram realizados alguns experimentos para determinar a influência de cada característica na performance do classificador (vide Seção 6.1.3). Estes experimentos apresentaram como resultado uma considerável melhoria quando são utilizadas as 5 características apresentadas na Seção 2.2.4.2. Desta forma, neste trabalho, foi utilizada uma rede LVQ com 5 unidades de entrada, correspondendo às 5 características analisadas. Os resultados dos experimentos realizados são resumidos na Seção 6.1.3.

A cada unidade de saída é associada uma classe. No entanto, na rede LVQ, pode-se ter mais de uma unidade de saída representando uma mesma classe. Neste trabalho, foram realizados alguns experimentos com o objetivo de avaliar a influência do número de unidades de saída na eficiência e no tempo de resposta da rede. Os resultados destes experimentos são apresentados na seção 6.1.2.

5.4.1.3 Configuração do classificador

Para possibilitar a realização dos experimentos apresentados nas seções 6.1.1, 6.1.2 e 6.1.3, foi construída uma interface gráfica para a configuração dos principais parâmetros do classificador. Esta interface é apresentada na Figura 5.4 e cada um de seus elementos é detalhado a seguir.

- No painel *Configuration* é possível ajustar os seguintes parâmetros:
 - Taxa de aprendizagem (α);
 - Número de unidades de classificação;
 - Taxa de decaimento de α ;
 - Número de classes;
 - Tolerância.

Deve-se ressaltar que a utilização eficaz da interface apresentada requer um breve treinamento do usuário, neste caso, o profissional de saúde responsável pela configuração do classificador. Este treinamento se faz necessário uma vez que os efeitos

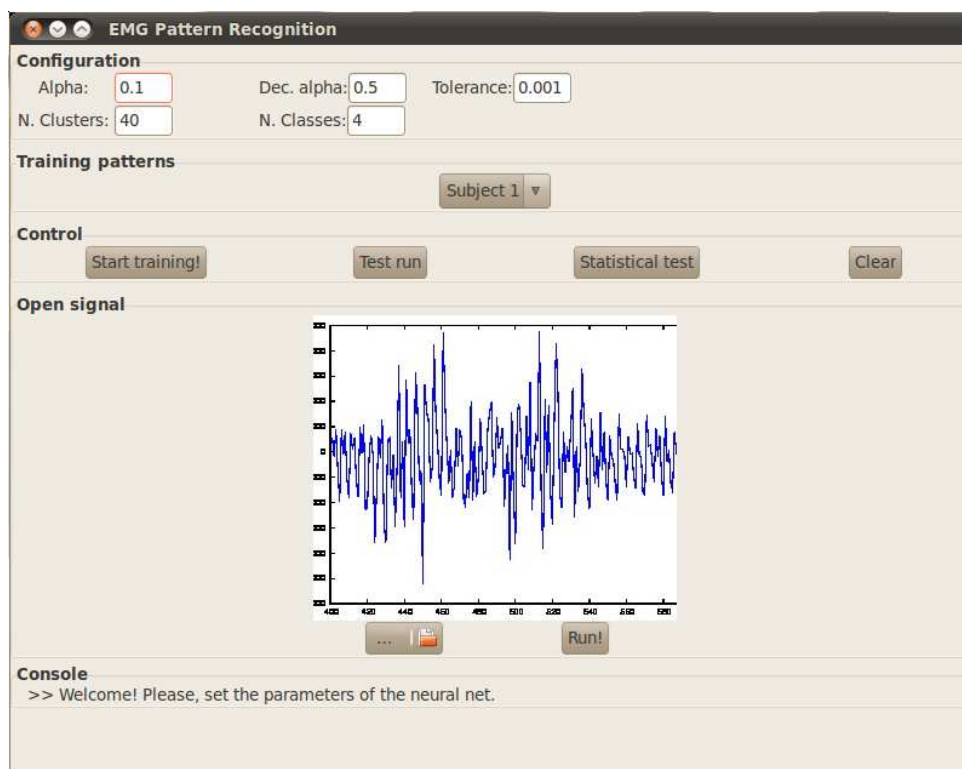



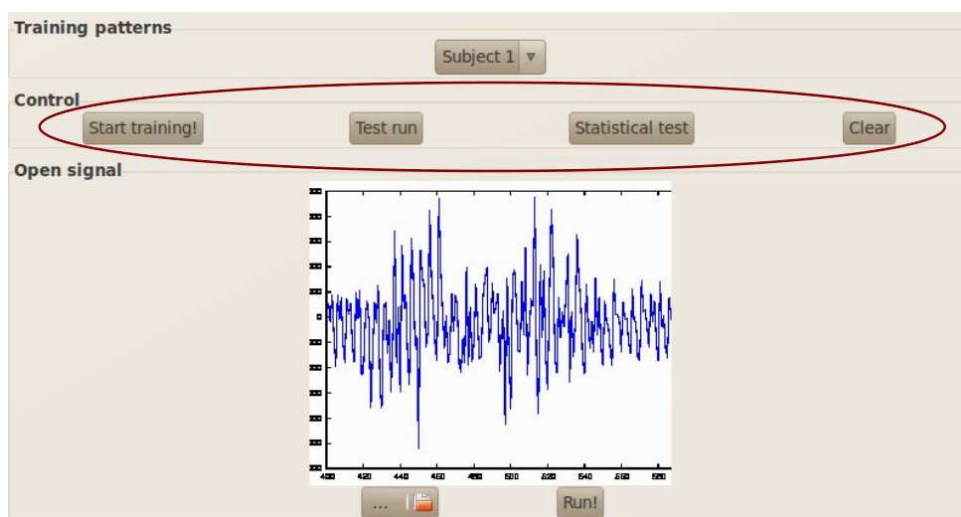
Figura 5.4: Interface de configuração do classificador.

da alteração dos parâmetros apresentados muitas vezes não são tão intuitivos, sobretudo para profissionais sem experiência em ferramentas computacionais aplicadas à saúde humana. No entanto, algumas estratégias podem ser utilizadas com o objetivo de adequar a interface apresentada a estes profissionais. Como exemplo, pode-se citar a utilização de Algoritmos Genéticos (AGs) para a configuração destes parâmetros [Rossi, Carvalho e Soares 2008, Grzesiak et al. 2007]. Desta forma, a interface ofereceria ao profissional de saúde uma série de configurações, com os respectivos resultados de performance obtidos após a execução do AG. Ao profissional de saúde, por sua vez, caberia a seleção daquela configuração que melhor atendesse o caso do paciente em tratamento.

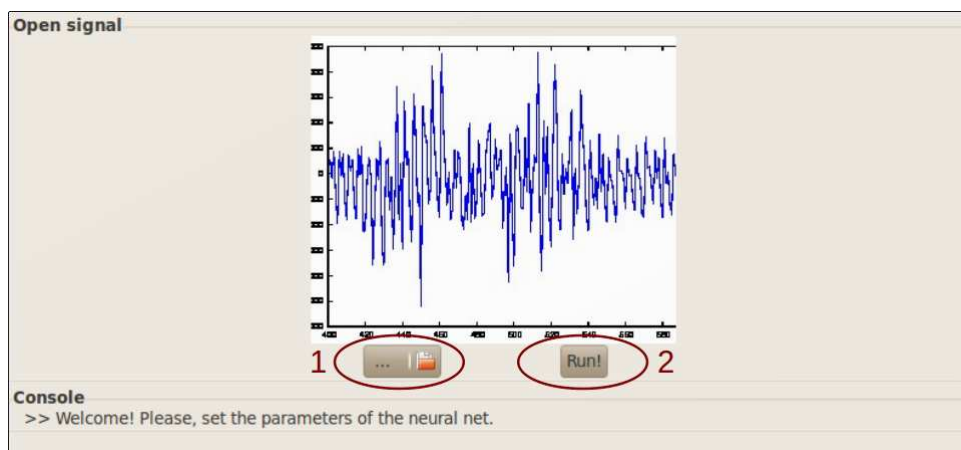
- No painel *Training patterns* é possível selecionar a base de dados que será utilizada para treinamento e teste da rede.
- O painel *Control* é composto pelos seguintes botões:
 - *Start training!*: inicia o treinamento da rede;
 - *Test run*: testa a rede com os padrões de treinamento;

Figura 5.5: Painel *Configuration*.Figura 5.6: Painel *Training patterns*.

- *Statistical test*: realiza 100 testes com os parâmetros de configuração selecionados e retorna parâmetros estatísticos dos testes realizados;
- *Clear*: retorna os parâmetros de configuração para os valores *default*.

Figura 5.7: Painel *Control*.

- No painel *Open signal* é possível carregar um sinal da base de dados (botão 1) e classificá-lo (botão 2).

Figura 5.8: Painel *Open signal*.

5.4.1.4 Algoritmo de treinamento

Para este trabalho, foi utilizado o algoritmo de treinamento apresentado na Seção 2.2.5.2. Para a inicialização dos pesos das unidades de saída, foi adotada a seguinte estratégia: no passo 0 do algoritmo são selecionados j padrões de treinamento, sendo j o número de unidades de saída. Estes padrões selecionados são atribuídos aos pesos das unidades de saída. Os padrões restantes são então utilizados para o treinamento da rede.

Como critério de parada, foi estabelecido um limite inferior para a taxa de aprendizagem. Uma vez que a taxa de aprendizagem é reduzida a cada ciclo de treinamento, a condição de parada é atingida quando o valor da taxa for inferior ao valor atribuído ao parâmetro *tolerância*. Com este critério de parada é possível limitar o número de ciclos de treinamento do classificador a partir da configuração do valor inicial de α , da taxa de decaimento de α e da tolerância.

A implementação do algoritmo discutido acima é apresentada na Figura 5.9.

5.4.2 Classificador MLP

A seguir, serão apresentados alguns detalhes de implementação do classificador MLP.

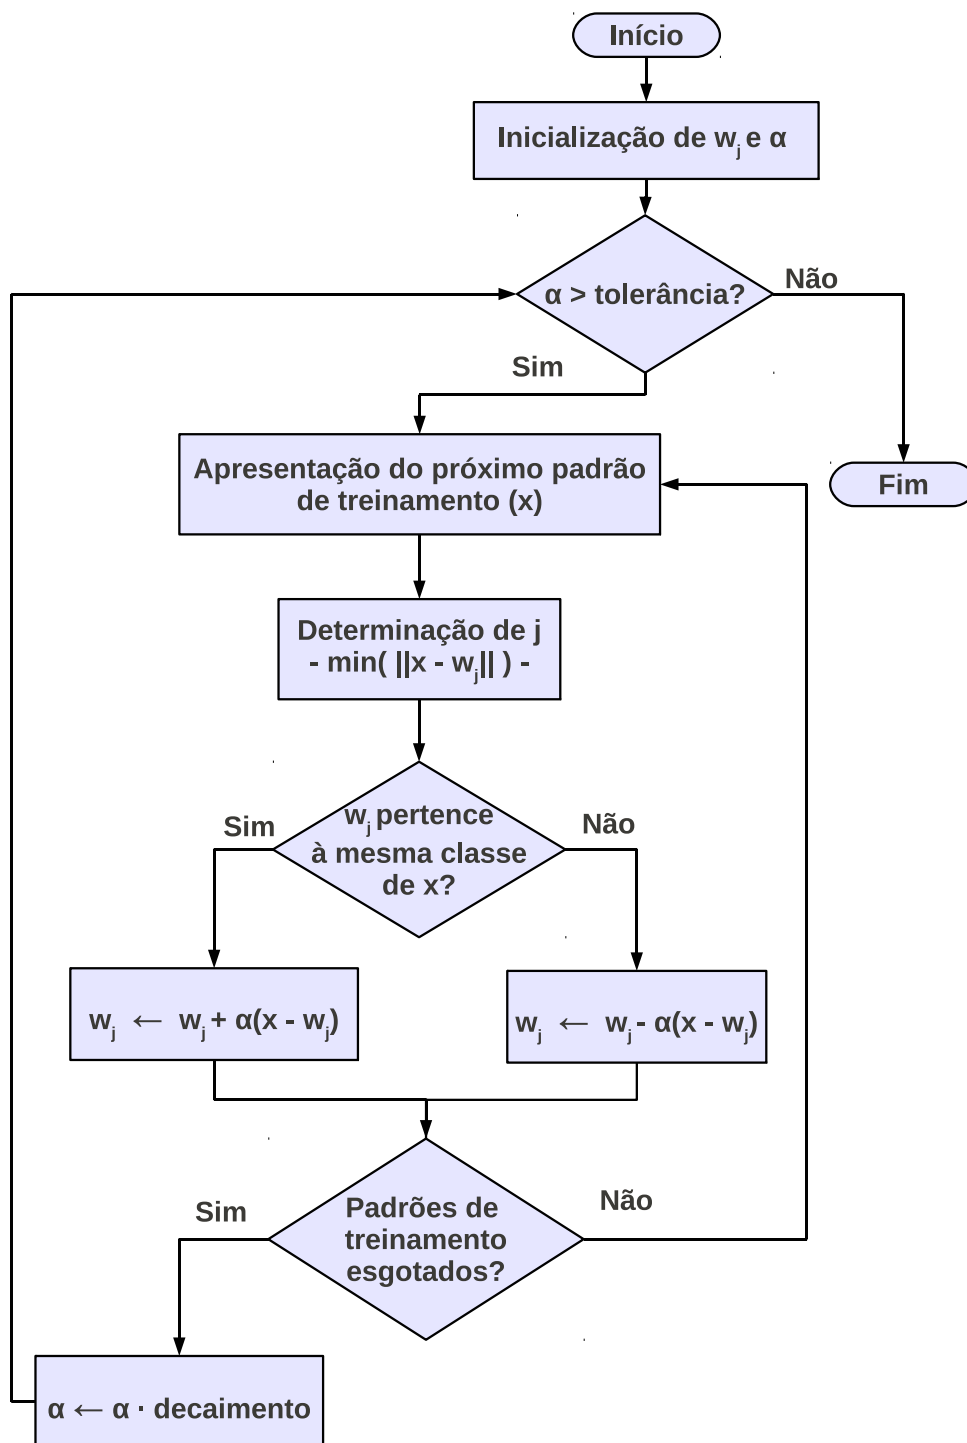


Figura 5.9: Algoritmo de treinamento da rede LVQ.

5.4.2.1 Arquitetura

A rede MLP implementada é apresentada na Figura 5.10. Observa-se que a mesma possui 5 neurônios de entrada (devido às 5 características consideradas), um número variável de neurônios na camada escondida e 4 neurônios na camada de saída.

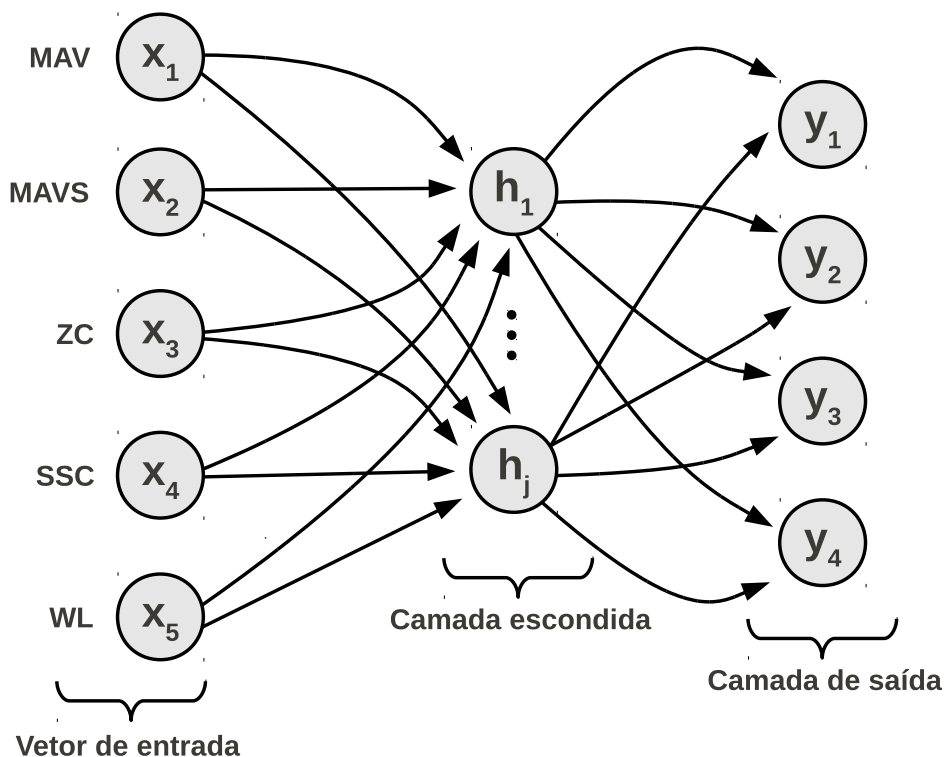


Figura 5.10: Arquitetura da rede MLP implementada.

Esta configuração, similar à configuração utilizada por Nogueira [Nogueira 2007] e Herle [Herle et al. 2008] na classificação de movimentos do braço, foi adaptada ao contexto do presente trabalho. Desta forma, a relação entre os 4 movimentos e a saída da rede é apresentada na Tabela 5.1.

Tabela 5.1: Saída da rede MLP

Movimento	y_1	y_2	y_3	y_4
Flexão do punho	1	-1	-1	-1
Extensão do punho	-1	1	-1	-1
Pronação do antebraço	-1	-1	1	-1
Flexão dos dedos	-1	-1	-1	1

5.4.2.2 Algoritmo de treinamento

Para o treinamento da rede MLP, foi utilizado o algoritmo padrão de retropropagação do erro (vide seção 2.2.5.1) com algumas modificações, apresentadas a seguir.

Função de ativação

Para se evitar a saturação da rede, os dados utilizados no treinamento foram normalizados no intervalo $[-1, 1]$. Desta forma, foi utilizada como função de ativação a sigmóide bipolar, apresentada na Equação 5.1 [Fausett 1994].

$$f(x) = \frac{2}{1 + e^{-x}} - 1 \quad (5.1)$$

Inicialização dos pesos

De acordo com Andrade [Andrade 2000], a inicialização dos pesos de Nguyen-Widrow pode ser utilizada para se reduzir o tempo de treinamento da rede MLP, quando aplicada à classificação de sinais EMG. Os detalhes deste procedimento, aplicado ao ajuste dos pesos da camada escondida, podem ser encontrados no trabalho de Fausett [Fausett 1994].

Momentum

Da mesma forma, para que a convergência da rede fosse atingida mais rapidamente, foi adaptada ao algoritmo implementado a retropropagação do erro utilizando o parâmetro *momentum*, conforme descrito por Fausett [Fausett 1994].

Critério de parada

Como critério de parada, para interromper o treinamento da rede, três abordagens foram utilizadas, seguindo as recomendações de Fausett [Fausett 1994]:

- *Erro quadrático total máximo*: quando o somatório dos erros quadráticos de cada neurônio de saída da rede é inferior à tolerância estabelecida, o treinamento é interrompido;

- *Número máximo de ciclos*: quando um número máximo de ciclos de treinamento é atingido, este é interrompido. Experimentalmente, verificou-se que com mais de 10000 ciclos de treinamento, dificilmente era observada a convergência da rede. Desta forma, foi utilizado este valor (10000) como número máximo de ciclos para o treinamento da rede;
- *Aumento do erro*: o último critério de parada corresponde ao aumento do erro em sucessivos ciclos de treinamento. Experimentalmente, verificou-se que quando o erro aumenta por mais de 100 ciclos consecutivos, a capacidade de convergência da rede é perdida. Desta forma, foi utilizado este valor como referência para este critério de parada.

5.5 Ambiente virtual

Nesta seção, serão discutidos os principais aspectos referentes à construção do ambiente virtual e sua adaptação à proposta deste trabalho.

5.5.1 Mão virtual

Para simular o comportamento de uma prótese real, o sistema de classificação foi integrado a um ambiente virtual, contendo uma mão virtual que reproduz os movimentos investigados neste trabalho. O modelo original, desenvolvido por Kator e Legaz [Kator e Legaz 2010] e registrado sob a licença *Creative Commons Attribution 3.0* [Commons 2010] foi adaptado para atender os requisitos do presente projeto. A adaptação consistiu na segmentação do modelo original (inicialmente, um modelo de um personagem virtual) e na reconstrução da armadura, que controla os movimentos do objeto virtual. A Figura 5.11 apresenta o modelo original segmentado (braço virtual) e a Figura 5.12 apresenta a armadura adaptada ao modelo.

5.5.2 Movimentos

Os 4 movimentos abordados neste trabalho (flexão, extensão e pronação do pulso e flexão dos dedos) foram implementados no modelo virtual posicionando-se os elementos da armadura correspondentes a cada movimento. Para cada um dos movimentos




Figura 5.11: Braço virtual utilizado. Adaptado de [Kator e Legaz 2010].




Figura 5.12: Armadura adaptada ao braço virtual.

foram utilizadas 3 posturas, sendo 1 postura inicial, 1 postura final e 1 postura intermediária. Em cada postura, são fixados as posições de cada elemento da armadura (*keyframes*). Finalmente, a transição entre os *keyframes* é construída interpolando-se as posturas definidas. Deve-se ressaltar que esta abordagem não possibilita o controle proporcional do modelo virtual, uma vez que tão logo seja detectado o movimento, o modelo virtual simulará este movimento por completo, como em uma ação de controle *on/off*.

As Figuras 5.13, 5.14, 5.15 e 5.16 apresentam os 4 movimentos abordados neste trabalho. Na parte esquerda das figuras, é possível notar a armadura utilizada para compor cada um dos movimentos, ressaltando-se que esta não faz parte do ambiente virtual renderizado. A partir da classificação dos sinais EMG utilizados, extraídos do músculo flexor radial do carpo (vide seção 5.3), a animação de um destes 4 movimentos é iniciada.



Figura 5.13: Flexão do pulso.




Figura 5.14: Extensão do pulso.



Figura 5.15: Pronação do pulso.



Figura 5.16: Flexão dos dedos.

5.5.3 Comunicação com o sistema de classificação

Visando implementar a comunicação entre o ambiente virtual e o sistema de classificação, foi adotada uma abordagem de comunicação entre processos. Nesta abordagem, o ambiente virtual é responsável por instanciar o sistema de classificação como um subprocesso e estabelecer um canal de comunicação com o subprocesso instanciado. Para a aplicação apresentada, a comunicação se dá de forma unidirecional, ou seja, sempre do sistema de classificação para o ambiente virtual (o sistema de classificação reconhece um movimento e em seguida solicita ao ambiente virtual que execute o movimento reconhecido). Desta forma, foi estabelecido um canal de comunicação do tipo *pipeline*, pelo qual a saída do processo responsável pela classificação está conectada à entrada do processo responsável pelo gerenciamento do ambiente virtual.

A Figura 5.17 apresenta, de forma simplificada, a arquitetura de comunicação entre os dois processos (classificação e ambiente virtual), baseada no diagrama de classes apresentado na Figura 4.6.

5.6 Processamento em tempo real

Com a finalidade de se avaliar o desempenho do protótipo desenvolvido quando aplicado à classificação de sinais em tempo real foi desenvolvida uma aplicação para

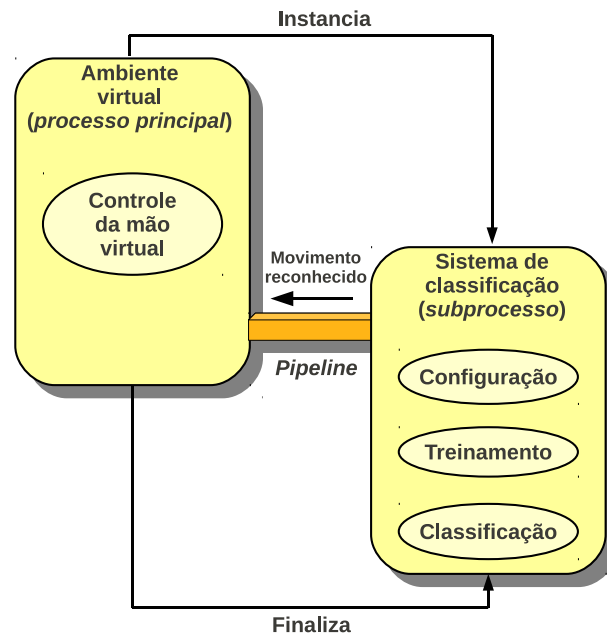


Figura 5.17: Comunicação entre o ambiente virtual e o sistema de classificação.

simular um sistema de aquisição de dados. A aplicação, apresentada na Figura 5.18, foi desenvolvida com base em uma arquitetura cliente-servidor.

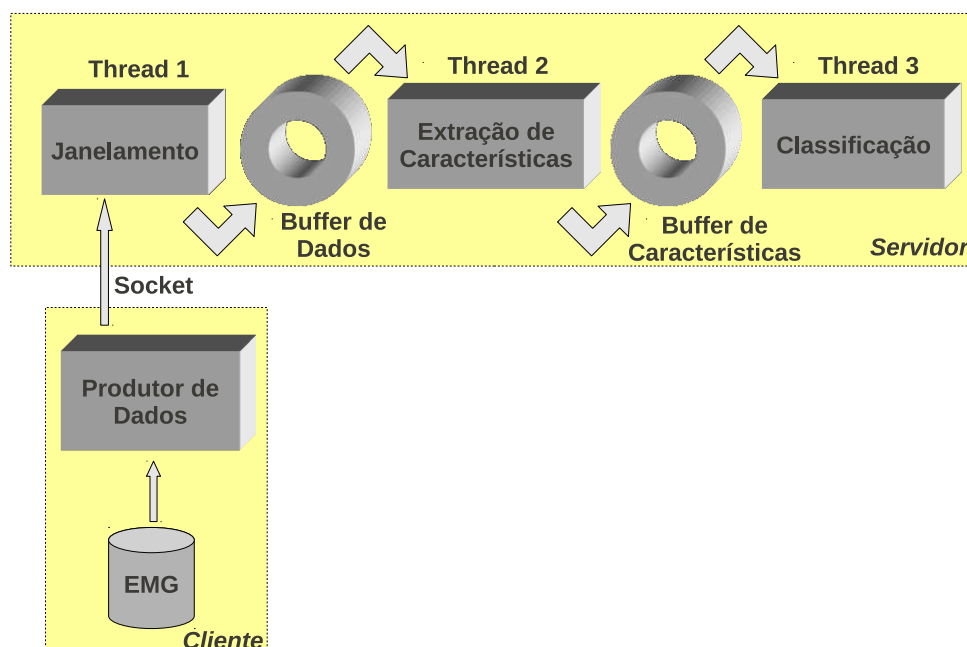


Figura 5.18: Simulador de aquisição/classificação em tempo real.

No módulo cliente, os dados EMG são lidos de uma base de dados e enviados diretamente ao servidor via *socket*. Para simular um sistema de aquisição real, os da-

dos são enviados a uma frequência fixa, que pode ser configurada para corresponder à frequência de amostragem do sistema de aquisição.

No módulo servidor, 3 *threads* operam paralelamente fazendo o janelamento dos dados, a extração de características e a classificação. O funcionamento de cada uma destas *threads* será detalhado a seguir.

5.6.1 Janelamento

Uma das etapas que influenciam diretamente a performance do classificador é o janelamento do sinal. O janelamento consiste, em linhas gerais, na seleção de determinado intervalo do sinal de entrada que contenha informações relevantes para o classificador. No caso do sistema apresentado, estes intervalos correspondem à realização dos movimentos, uma vez que a aquisição de dados é feita continuamente, mesmo que o músculo em questão esteja em repouso.

Diversas abordagens de janelamento foram utilizadas em trabalhos correlatos [Sebelius et al. 2005, Pons et al. 2005, Herle et al. 2008, Nogueira 2007]. Neste trabalho, foi utilizada como técnica de janelamento o operador de energia de Teager e Kaiser (TKEO) [Kaiser 1993], que permite determinar os intervalos de maior energia do sinal por meio de uma análise simultânea de amplitude e frequência. Esta técnica de janelamento foi utilizada em alguns trabalhos para o janelamento de sinais de voz [Peretta 2010, Zhou, Hansen e Kaiser 2001] e por Li *et al.* [Li e Aruin 2005, Li, Zhou e Aruin 2007] para o janelamento de sinais EMG.

O operador TKEO pode ser definido no tempo discreto como [Kaiser 1993]

$$\Psi[x(n)] = x_n^2 - x_{n+1} \cdot x_{n-1} \quad (5.2)$$

sendo x o vetor de amostras e n o índice da amostra.

A aplicação do operador consiste em calcular, para cada amostra, o valor de $\Psi[x(n)]$ e compará-lo a determinado limiar. Uma sequência de amostras para as quais $\Psi[x(n)]$ é superior ao limiar estabelecido representa um intervalo de alta energia do sinal. A Figura 5.19 apresenta uma sequência de movimentos da mão e o valor do operador TKEO quando aplicado a este sinal. É possível notar, pela observação dos gráficos, que os intervalos correspondentes à realização dos movimentos possuem maiores valores para o operador TKEO.




Figura 5.19: Exemplo de aplicação do operador TKEO.

Pela Equação 5.2, pode-se observar que para aplicar o operador TKEO em um sistema de aquisição de dados em tempo real é necessário armazenar temporariamente as amostras, para que se possa calcular o valor de $\Psi[x(n)]$, que depende do último valor de $x(n) - x_{n-1}$. Além disso, é necessário determinar um intervalo mínimo de atividade para que se considere determinada porção do sinal como relevante ou não. Por exemplo: é possível que determinada amostra, coletada dentro de uma região de

intensa atividade, tenha $\Psi[x(n)]$ inferior ao limiar estabelecido. No entanto, esta amostra representa um mínimo local, e o baixo valor de $\Psi[x(n)]$ não significa que a região de alta energia do sinal se encerrou.

Com base nestas observações, foram definidos experimentalmente alguns critérios para se discriminar os intervalos que contém informações relevantes ao classificador dos demais intervalos. São eles:

- Foi adotado um limiar $\epsilon = 10^6$.
- Para que uma porção do sinal seja considerada relevante, é preciso que suas amostras tenham TKEO superior a ϵ , por pelo menos 20 ms. Este valor é equivalente a 10% do tamanho da janela utilizada em outros trabalhos [Herle et al. 2008].
- Para que se detecte o fim da porção relevante do sinal, é preciso que as amostras desta porção tenham TKEO inferior a ϵ por pelo menos 20 ms (pela mesma justificativa do item anterior).

Finalmente, as janelas extraídas pela aplicação do TKEO são armazenadas em um buffer circular, denominado *buffer de dados*. Paralelamente à aquisição de novos sinais pela *thread* de janelamento, as janelas armazenadas no buffer serão apresentadas à *thread* de extração de características.

5.6.2 Extração de características

A *thread* de extração de características tem por função capturar as janelas de dados armazenadas no buffer de dados (pela *thread* de janelamento) e produzir os vetores de características correspondentes. Para tal, foi utilizada neste trabalho a mesma abordagem proposta por Herle *et al.* [Herle et al. 2008]: a janela de dados é inicialmente dividida em segmentos de 40 ms. Em seguida, é realizada a extração das características de cada segmento. Por fim, o vetor de características resultante é armazenado no *buffer* de características.

5.6.3 Classificação

A *thread* de classificação, por sua vez, espera que vetores de características estejam disponíveis no *buffer* de características. Quando um vetor de características está disponível, ele é classificado pela rede, utilizando os vetores de pesos obtidos em treinamento.

Com o objetivo de se melhorar a performance de classificação do sistema, uma estratégia de classificação, denominada MVS (*Majority Voting Scheme*) [Mattioli et al. 2011] foi utilizada. Esta estratégia de classificação consiste em agrupar segmentos da mesma janela de dados, i.e., referentes ao mesmo movimento, e classificar o movimento segundo a classificação obtida pela maioria dos seus segmentos. Um exemplo desta estratégia é apresentado na Figura 5.20.




Figura 5.20: Estratégia de classificação.

Na Figura 5.20, uma janela de dados é dividida em 5 segmentos. Em seguida, cada segmento é classificado independentemente pela rede, sem sobreposição de amostras. Por fim, uma vez que 3 segmentos obtiveram a classificação *C1* e 2 segmentos

a classificação C2, a janela é classificada como pertencente à classe C1.

5.7 Construção do protótipo

A partir dos elementos discutidos anteriormente, foi definida a arquitetura do protótipo apresentada na Figura 5.21.

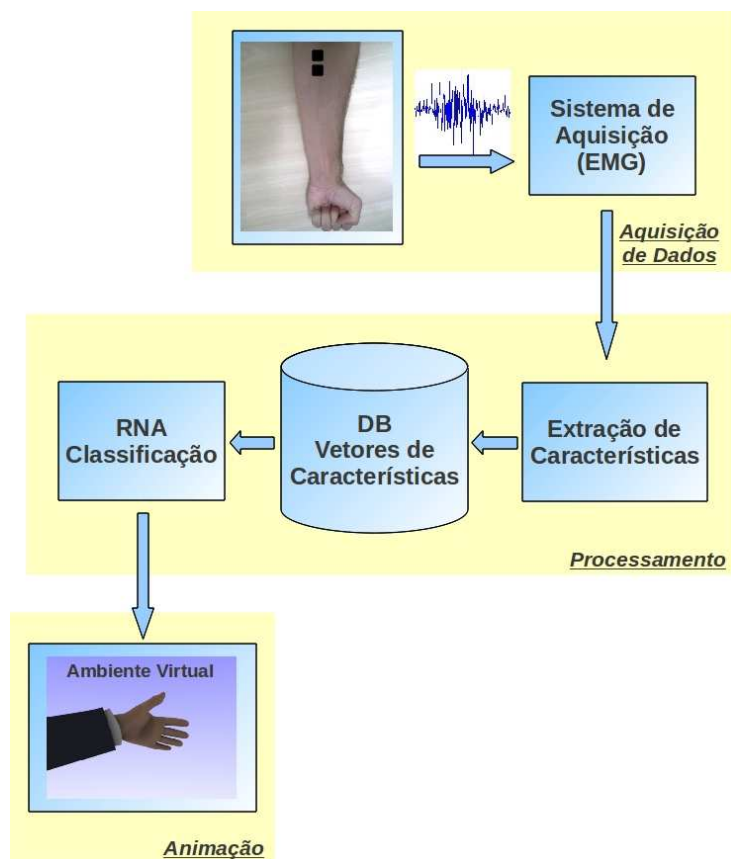


Figura 5.21: Arquitetura do protótipo.

O primeiro módulo do sistema é responsável pela aquisição de sinais EMG por meio de eletrodos posicionados nos músculos do paciente. No segundo módulo, é realizada a extração de características e a classificação dos vetores de características pela rede neural. Se necessário, as características extraídas podem ser armazenadas em uma base de dados, para que se possa ajustar o treinamento do classificador futuramente. Finalmente, em um ambiente virtual é reproduzido o movimento reconhecido pela rede, de modo que o paciente tenha um *feedback* visual do resultado da classificação.

5.8 Considerações finais

Neste capítulo, foram discutidos os principais detalhes de implementação do protótipo apresentado neste trabalho. No próximo capítulo, será apresentada uma breve discussão dos resultados obtidos bem como alguns experimentos realizados para se fundamentar as conclusões deste trabalho.

Capítulo 6

Discussão dos resultados

Neste capítulo, será apresentada uma discussão dos resultados obtidos neste trabalho de pesquisa.

6.1 Performance do classificador LVQ

Durante a realização deste trabalho, foi possível notar a influência de diversos fatores na performance do classificador. Com o objetivo de se analisar quantitativamente esta influência, foram realizados alguns testes que serão apresentados a seguir.

6.1.1 Influência dos parâmetros de configuração

Os parâmetros de configuração da rede neural (taxa de aprendizagem, decaimento da taxa de aprendizagem e tolerância) possuem influência direta na performance e no tempo de treinamento da rede neural. Para se quantificar a influência de cada parâmetro, foi adotada a seguinte abordagem:

1. Mantendo-se os demais parâmetros fixos nos valores *default*, o parâmetro em análise é alterado, dentro de uma faixa de valores previamente estabelecidos. Os valores *default* utilizados na configuração padrão são:

- $\alpha = 0,1$;
- Taxa de decaimento de $\alpha = 0,5$;
- Tolerância = 0,001;

- Número de unidades de saída = 40;
2. São realizados 100 testes com o parâmetro em análise no valor alterado. A realização dos 100 testes é necessária, uma vez que a inicialização dos pesos das unidades de saída se dá de forma aleatória (padrões de treinamento são aleatoriamente selecionados para inicialização). Desta forma, redes com vetores de pesos iniciais diferentes têm características (performance, tempo gasto no treinamento) diferentes.
 3. Para cada teste realizado é calculada a eficiência da rede, dividindo-se o número de padrões corretamente classificados ($N_{corretos}$) pelo número total de padrões de teste (N_{total}). A equação 6.1 foi utilizada para o cálculo da eficiência do classificador [Li, Schultz e Kuiken 2010].

$$E = 100 \times \frac{N_{corretos}}{N_{total}} \quad (6.1)$$

4. Para a análise de performance, são calculados a média e o intervalo de confiança da média (95%) dos 100 testes.
5. Para avaliar a influência de cada parâmetro no tempo de treinamento da rede, foi adaptado ao código fonte da rede neural um *timer* auxiliar, iniciado antes e parado após o treinamento. O tempo de treinamento foi medido em um Desktop com a seguinte configuração:
 - Sistema operacional: Ubuntu Linux, 10.04 (kernel 2.6.32).
 - Processador Intel® Core™ 2 Quad Q8200, 2.33 GHz.
 - 4 GB de memória RAM.

Os resultados dos testes realizados são apresentados a seguir.

6.1.1.1 Taxa de aprendizagem (α)

A taxa de aprendizagem (α) foi variada de 0,01 a 0,99, de acordo com as recomendações de Fausett [Fausett 1994]. A Figura 6.1 apresenta a variação da eficiência da rede em função da variação de α .




Figura 6.1: Eficiência da rede x taxa de aprendizagem.

É possível observar que para valores de α entre 0,1 e 0,4 os testes apresentaram melhor eficiência da rede. Já para valores mais altos de α , observa-se uma redução na performance de classificação da rede. Este fato pode ser explicado pela influência que a taxa de aprendizagem exerce no ajuste dos pesos das unidades de saída do classificador (seção 2.2.5.2).

Na Figura 6.2, é apresentado o impacto da variação de α no tempo de treinamento da rede. Observa-se que quanto maior o valor de α maior o tempo de treinamento da rede. A justificativa para tal fato é o critério de parada adotado (o treinamento é interrompido quando α atinge um valor inferior à tolerância). Desta forma, maiores valores de α correspondem a mais ciclos de treinamento, uma vez que o valor de α é reajustado após cada ciclo.

6.1.1.2 Taxa de decaimento de α

A Figura 6.3 apresenta a eficiência da rede em função da taxa de decaimento de α , para valores de decaimento de 0,01 a 0,99.

Pode-se observar que para valores muito altos de decaimento de α ocorre uma redução significativa na eficiência do classificador. Isto se deve ao fato de taxas de




Figura 6.2: Tempo de treinamento x taxa de aprendizagem.




Figura 6.3: Eficiência da rede x decaimento de α .

decaimento muito altas provocarem a redução lenta de α , o que resulta em alterações significativas no reajuste dos pesos da rede a cada ciclo de treinamento.

A influência da taxa de decaimento de α no tempo de treinamento da rede é apre-

sentada na Figura 6.4.




Figura 6.4: Tempo de treinamento x decaimento de α .

Observa-se que valores altos da taxa de decaimento representam um aumento considerável no tempo de treinamento do classificador. Este efeito é justificável, uma vez que taxas de decaimento mais altas correspondem a uma redução lenta de α e, consequentemente, mais ciclos de treinamento.

6.1.1.3 Tolerância

A Figura 6.5 apresenta a influência da tolerância na performance de classificação da rede, para valores de tolerância de 0,001 a 0,099.

É possível verificar que com o aumento da tolerância ocorre uma redução na eficiência do classificador. Tal fato justifica-se pela redução do número de ciclos de treinamento. Valores muito altos de tolerância correspondem a poucos ciclos de treinamento, o que provoca a queda da performance do classificador.

A Figura 6.6 apresenta a influência da tolerância no tempo de treinamento da rede.

Nota-se que o aumento da tolerância corresponde a uma redução do tempo de treinamento da rede, uma vez que menos ciclos de treinamento são executados.




Figura 6.5: Eficiência da rede x tolerância.




Figura 6.6: Tempo de treinamento x tolerância.

6.1.2 Influência do número de unidades de saída

Para avaliar a influência do número de unidades de saída na eficiência da rede foram realizados testes variando este número de 4 a 60. A escolha deste intervalo de testes

se deve aos 4 movimentos abordados (4 classes) e à quantidade de padrões disponíveis para o treinamento da rede (aproximadamente 80 padrões para cada indivíduo). Uma vez que a rede LVQ deste trabalho é inicializada com os próprios padrões de treinamento, verificou-se, experimentalmente, que um número de unidades de saída superior a 60 resulta na perda da capacidade de generalização da rede. Além disso, para que se obtivesse sempre o mesmo número de unidades de saída para cada classe, este número sempre deve representar um múltiplo de 4. A influência do número de unidades de saída na performance de classificação da rede é apresentada na Figura 6.7.




Figura 6.7: Eficiência da rede x número de unidades de saída.

Pela Figura 6.7 é possível observar o aumento significativo da eficiência do classificador com o aumento do número de unidades de saída. Esta característica se justifica pelo fato de um número maior de unidades de saída fornecer uma representação melhor de um grupo heterogêneo de características. Enquanto se tem 5 unidades de saída para cada classe é possível representar 5 vetores de características diferentes para uma mesma classe. Aumentando-se este número, mais vetores são representados o que resulta em mais acertos na classificação dos padrões.

A influência do número de unidades de saída no tempo de treinamento da rede é

apresentada na Figura 6.8.




Figura 6.8: Tempo de treinamento x número de unidades de saída.

Na Figura 6.8 é possível observar duas respostas características: um aumento no tempo de treinamento da rede (no intervalo de 4 a 36 unidades de saída) e na sequência uma redução neste tempo (no intervalo de 36 a 60 unidades de saída). Isto se explica pelo fato de ter sido utilizada a mesma quantidade de padrões de treinamento em todos os testes. Na medida em que se aumenta a quantidade de unidades de saída, mais padrões são utilizados para inicialização dos pesos. Como os padrões utilizados para inicialização são descartados, o conjunto de padrões de treinamento é reduzido com o aumento das unidades de saída. Esta redução dos padrões de treinamento resulta na queda do tempo de treinamento observada na Figura 6.8, a partir de 36 unidades de saída.

Deve-se ressaltar que o aumento do número de unidades de classificação, apesar de resultar na melhoria da performance da rede para um mesmo conjunto de padrões de treinamento, pode resultar também na perda da capacidade de generalização do classificador. Isto se deve ao fato de o classificador ser inicializado com os próprios padrões de treinamento, ficando “habitado” aos padrões de treinamento. Desta forma, é aconselhável que um aumento no número de unidades de saída seja acompanhado

de um aumento no número de padrões de treinamento. Uma outra solução para este problema pode ser a atualização dos pesos de mais de uma unidade para cada padrão de treinamento (“vizinhança”) [Fausett 1994].

6.1.3 Influência das características do sinal

Com o objetivo de se avaliar a influência de cada uma das características apresentadas na seção 2.2.4.2 na performance do classificador, foram realizados testes com subconjuntos destas características. Para isso, foram realizados, para cada combinação de características, 100 testes de performance. Os gráficos apresentados a seguir mostram, para cada combinação de características, quantos testes obtiveram eficiência superior a 90%, quantos testes obtiveram eficiência entre 80 e 90% e quantos testes obtiveram eficiência inferior a 80%.

A Figura 6.9 apresenta os resultados obtidos para combinações das 5 características, tomadas 2 a 2. A Figura 6.10 apresenta os resultados obtidos para combinações das 5 características tomadas 3 a 3. Na Figura 6.11 são apresentados os resultados para combinações das 5 características tomadas 4 a 4. Por fim, na Figura 6.12 são apresentados os resultados obtidos quando utilizadas todas as 5 características.




Figura 6.9: Resultados dos testes com 2 características.




Figura 6.10: Resultados dos testes com 3 características.




Figura 6.11: Resultados dos testes com 4 características.

Pelos resultados apresentados, é possível notar que as 2 características de maior contribuição para a performance do classificador são a *MAV* e o *MAVS*. Percebe-se ainda que na medida em que as características são agrupadas, ocorre uma melhor




Figura 6.12: Resultados dos testes com 5 características.

distribuição dos resultados com eficiência superior a 90%. Por exemplo, na Figura 6.11 observa-se que independentemente das características utilizadas, os testes cujos resultados apresentam eficiência superior a 90% são sempre a maioria.

6.2 Performance do classificador MLP

Com o objetivo de se avaliar o desempenho da rede MLP na classificação dos sinais considerados, foram realizados dois testes de performance, apresentados nas seções 6.2.0.2 e 6.2.0.1. Tal como na Seção 6.1.1, foram fixados os valores da configuração padrão da rede, variando-se apenas o parâmetro em avaliação. Os valores *default* utilizados na configuração padrão são:

- $\alpha = 0,1$;
- *Momentum* (μ) = 0,9;
- Número de neurônios na camada escondida = 20;
- Número de neurônios na camada de saída 4.

6.2.0.1 Taxa de aprendizagem (α)

As figuras 6.13 e 6.14 apresentam, respectivamente, a variação da performance de classificação e do tempo de treinamento da rede MLP em função da taxa de aprendizagem.




Figura 6.13: Eficiência da rede x taxa de aprendizagem.

Pode-se observar, pela análise da Figura 6.13, que na medida em que se aumenta a taxa de aprendizagem (α), ocorre uma queda na performance de classificação da rede. Além disso, para valores mais altos de α observa-se uma maior dispersão dos dados de eficiência da rede. Este fato se explica pela maior dificuldade de convergência da rede quando são utilizados valores mais altos para a taxa de aprendizagem. Para taxas de aprendizagem superiores a 0,7, a convergência foi observada apenas em 2% dos testes realizados.

É possível observar ainda, pela Figura 6.14, que o tempo de treinamento da rede aumenta no intervalo de 0,1 a 0,3 e decresce a partir de 0,3. No entanto, este decréscimo no tempo de treinamento corresponde a um decréscimo também na performance de classificação e na capacidade de convergência da rede.




Figura 6.14: Tempo de treinamento x taxa de aprendizagem.

6.2.0.2 Número de neurônios da camada escondida

As figuras 6.15 e 6.16 apresentam, respectivamente, a variação da performance de classificação e do tempo de treinamento da rede MLP em função do número de neurônios na camada escondida.

Observa-se que ocorre um aumento na performance de classificação da rede MLP na medida em que mais neurônios são acrescentados à camada escondida. No entanto, deve-se ressaltar que com mais de 30 neurônios nesta camada, a rede não foi capaz de convergir para um resultado final (a convergência foi observada em menos de 5% dos testes realizados nesta situação).

Em todos os testes realizados com a rede MLP não foi possível observar performances de classificação superiores a 85%. Além disso, o tempo de treinamento da rede MLP (aproximadamente 100 segundos para performances médias próximas a 70%) mostrou-se bem superior ao da rede LVQ (da ordem de 10^{-3} segundos para performances médias próximas a 80%). Estes dois fatores motivaram a escolha da rede LVQ como sistema de classificação utilizado neste trabalho.




Figura 6.15: Eficiência da rede x neurônios na camada escondida.




Figura 6.16: Tempo de treinamento x neurônios na camada escondida.

6.3 Considerações finais

Neste capítulo, discutiu-se a influência de diversos parâmetros na performance de classificação do protótipo construído. Observou-se um aumento na eficiência de clas-

sificação da rede LVQ quando são utilizados valores baixos (próximos a 0,1) para a taxa de aprendizagem e para o decaimento da taxa de aprendizagem. Além disso, foi possível observar que a utilização simultânea das 5 características (*MAV*, *MAVS*, *ZC*, *SSC* e *WL*) resulta, na maioria dos testes realizados, em performances de classificação superiores a 90%. No entanto, pode-se verificar que as duas características de maior contribuição para estes resultados são a *MAV* e a *MAVS*.

O Quadro 6.1 apresenta a contribuição deste trabalho em comparação aos trabalhos correlatos analisados no Capítulo 3. No próximo capítulo, serão apresentadas as conclusões deste trabalho e as sugestões para trabalhos futuros.

Quadro 6.1: Resumo comparativo dos trabalhos correlatos e do presente trabalho

Trabalhos relacionados	Movimentos da mão	Janelamento por TKEO	Características no domínio do tempo	Classificador LVQ	Teste de performance em tempo real
Chu, 2006	✓	✗	✗	✗	✓
Sebelius, 2005	✓	✗	✗	✗	✓
Pons, 2005	✓	✗	✗	✗	✓
Herle, 2008	✗	✗	✓	✗	✗
Nogueira, 2007	✗	✗	✗	✗	✓
Mattioli, 2012	✓	✓	✓	✓	✓

Capítulo 7

Conclusões e trabalhos futuros

7.1 Introdução

Neste capítulo, destacam-se os aspectos da pesquisa e conclusões do trabalho apresentado nesta dissertação. Além disso, serão apresentadas algumas sugestões para trabalhos futuros e a contribuição científica do presente trabalho.

7.2 Conclusões

O grande esforço mental despendido por usuários de próteses mioelétricas durante a fase de treinamento é um dos fatores que culminam na desistência de muitos pacientes neste estágio do processo de reabilitação. Ambientes virtuais de treinamento utilizados na simulação e no controle de próteses mioelétricas podem contribuir, de forma significativa, como tecnologias assistivas em reabilitação humana pós-amputação. Dentre os diversos benefícios oferecidos por estes ambientes está a possibilidade de se oferecer aos pacientes um ambiente de treinamento adaptável, versátil e, ao mesmo tempo, livre dos riscos inerentes ao ambiente real. Desta forma, o objetivo deste trabalho foi projetar um sistema de treinamento em Realidade Virtual para usuários de próteses mioelétricas de mão. Neste contexto, era necessário que o sistema possuísse uma boa performance de classificação (em tempo real) dos sinais EMG e uma rápida comunicação entre o classificador de sinais e o ambiente virtual. Para tal, foram utilizadas técnicas de processamento digital de sinais e Redes Neurais Artificiais, além de ferramentas para a construção de ambientes virtuais. As técnicas

utilizadas na extração de características e na classificação dos sinais possibilitaram que o classificador atingisse, na maioria das vezes, performances de classificação superiores a 90%, chegando a 100% em alguns testes realizados com a rede LVQ. Esta performance de classificação, relacionada aos movimentos da mão, encontra-se na mesma faixa dos valores obtidos em trabalhos correlatos [Herle et al. 2008, Soares et al. 2003, Nogueira 2007] para a classificação de movimentos do braço. O tempo gasto para o treinamento do classificador LVQ, da ordem de 10^{-3} segundos, apresenta-se adequado à aplicação considerada. Contudo, para os movimentos investigados neste estudo, não foi possível obter performances de classificação superiores a 85% nos testes realizados com a rede MLP.

A técnica de classificação proposta possibilitou um aumento de 5% em média na performance de classificação, quando comparado à classificação individual de cada segmento. O atraso de resposta observado nos testes de processamento em tempo real - devido ao janelamento e extração de características - não foi significativo, uma vez que corresponde a um pequeno aumento no tempo de resposta global do sistema. Uma avaliação quantitativa do efeito deste atraso de resposta sugere uma interessante proposta para trabalhos futuros.

Ambientes virtuais de treinamento constituem, ainda, uma ferramenta auxiliar de monitoramento e avaliação de usuários em potencial deste tipo de prótese. A possibilidade de integrar o protótipo apresentado neste trabalho a uma base de dados, de forma a produzir automaticamente relatórios com os resultados das seções de treinamento, é um dos principais fatores que ressaltam sua aplicabilidade e uso por profissionais da área da saúde.

7.3 Trabalhos futuros

Outras sugestões para trabalhos futuros são:

- Avaliação do impacto da utilização de outras características, tais como coeficientes auto-regressivos ou características no domínio da frequência, na performance do classificador;
- Extensão do sistema proposto a outros tipos de movimentos, por exemplo, a flexão individual de cada dedo da mão;

- Avaliação quantitativa da performance de diferentes classificadores, tais como *support vector machines* ou *k-nearest neighbours*, na discriminação dos movimentos abordados neste trabalho.

7.4 Considerações finais

Com este trabalho, foi possível realizar uma avaliação de alguns dos principais componentes de um sistema de treinamento para usuários de próteses mioelétricas de mão em Realidade Virtual. Do ponto de vista científico, as principais contribuições deste trabalho são:

- Avaliação da aplicação do algoritmo de janelamento automático, baseado no operador TKEO, aos sinais EMG considerados;
- Avaliação da rede neural LVQ como classificador dos sinais EMG considerados;
- Análise da contribuição de cada uma das características temporais consideradas neste trabalho na performance de classificação do sistema;
- Proposta da arquitetura de comunicação cliente/servidor entre o sistema de classificação e o ambiente virtual, em uma aplicação em tempo real.

Referências bibliográficas

- [Akay 1994] AKAY, M. *Biomedical signal processing*. [S.l.]: Academic Press San Diego, 1994.
- [Ambler 2002] AMBLER, S. *Agile modeling*. [S.l.]: Wiley, 2002.
- [Andrade 2000] ANDRADE, A. de O. *Metodologia para Classificação de Sinais EMG no Controle de Membros Artificiais*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia, Janeiro 2000.
- [Atkeson, Moore e Schaal 1997] ATKESON, C.; MOORE, A.; SCHAAL, S. Locally weighted learning. *Artificial intelligence review*, Springer, v. 11, n. 1, p. 11–73, 1997.
- [Batteau et al. 2004] BATTEAU, L. et al. A study on the perception of haptics in surgical simulation. *Medical Simulation*, Springer, p. 185–192, 2004.
- [Beck 2004] BECK, K. *Programação extrema explicada: acolha as mudanças*. Porto Alegre: Bookman, 2004.
- [Brinkman, Sandino e Mast 2009] BRINKMAN, W.; SANDINO, G.; MAST, C. V. D. Field observations of therapists conducting virtual reality exposure treatment for the fear of flying. In: VTT TECHNICAL RESEARCH CENTRE OF FINLAND. *European Conference on Cognitive Ergonomics: Designing beyond the Product—Understanding Activity and User Experience in Ubiquitous Environments*. [S.l.], 2009. p. 18.
- [Bruce e Regenbrecht 2009] BRUCE, M.; REGENBRECHT, H. A virtual reality claustrophobia therapy system. *IEEE Virtual Reality*, IEEE, 2009.
- [Burdea 2002] BURDEA, G. Keynote address: Virtual rehabilitation-benefits and challenges. In: *1st International Workshop on Virtual Reality Rehabilitation (Mental Health, Neurological, Physical, Vocational) VRMHR*. [S.l.: s.n.], 2002. p. 7–18.

- [Cai et al. 2011] CAI, Z. et al. Design & control of a 3d stroke rehabilitation platform. In: IEEE. *Proceedings of the 2011 IEEE International Conference on Rehabilitation Robotics*. [S.l.], 2011.
- [Cardoso e Lamounier 2006] CARDOSO, A.; LAMOUNIER, E. *Fundamentos e tecnologia de Realidade Virtual e Aumentada*. Porto Alegre: Editora SBC, 2006. A Realidade Virtual na Educação e Treinamento.
- [Choi et al. 2009] CHOI, C. et al. Development and quantitative performance evaluation of a noninvasive emg computer interface. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 56, n. 1, p. 188–191, 2009.
- [Chu, Moon e Mun 2006] CHU, J.; MOON, I.; MUN, M. A real-time EMG pattern recognition system based on linear-nonlinear feature projection for a multifunction myoelectric hand. *IEEE Transactions on Biomedical Engineering*, v. 53, n. 11, p. 2232–2239, 2006.
- [Commons 2010] COMMONS, C. *Creative Commons Attribution 3.0*. 2010. Disponível em: <<http://creativecommons.org/licenses/by/3.0/us>>.
- [Costa e Ribeiro 2009] COSTA, R. M.; RIBEIRO, M. W. (Ed.). *Aplicações de Realidade Virtual e Aumentada - Livro do pré-simpósio do SVR2009*. Porto Alegre: SBC, 2009.
- [Craelius, Abboudi e Newby 1999] CRAELIUS, W.; ABBOUDI, R. L.; NEWBY, N. A. Control of a multi-finger prosthetic hand. In: *Proceedings of the International Conference on Rehabilitation Robotics*. [S.l.: s.n.], 1999. p. 255–260.
- [Englehart, Hudgin e Parker 2001] ENGLEHART, K.; HUDGIN, B.; PARKER, P. A wavelet-based continuous classification scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 48, n. 3, p. 302–311, 2001.
- [Englehart e Hudgins 2003] ENGLEHART, K.; HUDGINS, B. A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 50, n. 7, p. 848–854, 2003.
- [Fausett 1994] FAUSETT, L. (Ed.). *Fundamentals of neural networks: architectures, algorithms, and applications*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1994. ISBN 0-13-334186-0.

- [Fowler 2004] FOWLER, M. *UML distilled: a brief guide to the standard object modeling language*. [S.l.]: Addison-Wesley Professional, 2004.
- [Globo.com 2010] Globo.com. *Diabetes é maior causa de amputação no Brasil*. 2010. Disponível em: <<http://g1.globo.com/bom-dia-brasil/noticia/2010/05/diabetes-e-maior-causa-de-amputacoes-no-brasil.html>>. Acesso em: 13 maio 2011.
- [Grzesiak et al. 2007] GRZESIAK, L. et al. Genetic algorithm for parameters optimization of ann-based speed controller. In: IEEE. *EUROCON, 2007. The International Conference on "Computer as a Tool"*. [S.l.], 2007. p. 1700–1705.
- [Guo et al. 2006] GUO, X. et al. Study of the control mechanism of robot-prosthesis based-on the emg processed. In: IEEE. *Intelligent Control and Automation, 2006. WCICA 2006. The Sixth World Congress on*. [S.l.], 2006. v. 2, p. 9490–9493.
- [Gutierrez e Munoz 2011] GUTIERREZ, J.; MUNOZ, R. Wavelet neural network as emg classifier. In: IEEE. *Health Care Exchanges (PAHCE), 2011 Pan American*. [S.l.], 2011. p. 67–71.
- [Hattori e Takahashi 1999] HATTORI, K.; TAKAHASHI, M. A new nearest-neighbor rule in the pattern classification problem. *Pattern recognition*, Elsevier, v. 32, n. 3, p. 425–432, 1999.
- [Haykin 1999] HAYKIN, S. *Neural networks: a comprehensive foundation*. Upper Saddle River, NJ, USA: Prentice Hall, 1999.
- [He et al. 2006] HE, L. et al. Recognition of ecg patterns using artificial neural network. In: IEEE. *Intelligent Systems Design and Applications, 2006. ISDA'06. Sixth International Conference on*. [S.l.], 2006. v. 2, p. 477–481.
- [HealthCare 2011] HEALTHCARE, O. B. *Otto Bock Homepage*. 2011. Disponível em: <<http://www.ottobockus.com/>>. Acesso em: 10 jun 2011.
- [Hefftner, Zucchini e Jaros 1988] HEFFTNER, G.; ZUCCHINI, W.; JAROS, G. The electromyogram (emg) as a control signal for functional neuromuscular stimulation. i. autoregressive modeling as a means of emg signature discrimination. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 35, n. 4, p. 230–237, 1988.

- [Heim 2000] HEIM, M. *Virtual realism*. [S.l.]: Oxford University Press, USA, 2000.
- [Herle et al. 2008] HERLE, S. et al. Classification of surface electromyographic signals for control of upper limb virtual prosthesis using time-domain features. In: IEEE. *Proceedings of the 2008 IEEE International Conference on Automation, Quality and Testing, Robotics*. [S.l.], 2008. p. 160–165.
- [Hesse e Herrmann 2010] HESSE, F.; HERRMANN, J. Homeokinetic proportional control of myoelectric prostheses. In: IEEE. *Intelligent Robots and Systems (IROS), 2010 IEEE/RSJ International Conference on*. [S.l.], 2010. p. 1786–1791.
- [Hiraiwa, Shimohara e Tokunaga 1989] HIRAIWA, A.; SHIMOHARA, K.; TOKUNAGA, Y. Emg pattern analysis and classification by neural network. In: IEEE. *Systems, Man and Cybernetics, 1989. Conference Proceedings., IEEE International Conference on*. [S.l.], 1989. p. 1113–1115.
- [Hochberg et al. 2006] HOCHBERG, L. R. et al. Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature*, Nature Publishing Group, v. 442, n. 7099, p. 164–171, 2006.
- [Hosseini, Luo e Reynolds 2006] HOSSEINI, H.; LUO, D.; REYNOLDS, K. The comparison of different feed forward neural network architectures for ecg signal diagnosis. *Medical engineering & physics*, Elsevier, v. 28, n. 4, p. 372–378, 2006.
- [Huang et al. 2003] HUANG, H. et al. Emg classification for prehensile postures using cascaded architecture of neural networks with self-organizing maps. In: IEEE. *Proceedings of the IEEE International Conference on Robotics and Automation 2003*. [S.l.], 2003. v. 1, p. 1497–1502.
- [Hudgins, Parker e Scott 1993] HUDGINS, B.; PARKER, P.; SCOTT, R. A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, v. 40, n. 1, p. 82–94, 1993.
- [Hunt 2006] HUNT, J. *Agile software construction*. London: Springer, 2006.
- [Jack et al. 2001] JACK, D. et al. Virtual reality-enhanced stroke rehabilitation. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, IEEE, v. 9, n. 3, p. 308–318, 2001.

- [Janghel et al. 2010] JANGHEL, R. et al. Breast cancer diagnosis using artificial neural network models. In: IEEE. *Information Sciences and Interaction Sciences (ICIS), 2010 3rd International Conference on*. [S.l.], 2010. p. 89–94.
- [Jiang, Englehart e Parker 2009] JIANG, N.; ENGLEHART, K.; PARKER, P. Extracting simultaneous and proportional neural control information for multiple-dof prostheses from the surface electromyographic signal. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 56, n. 4, p. 1070–1080, 2009.
- [Kaiser 1993] KAISER, J. Some useful properties of Teager's energy operators. In: IEEE. *Acoustics, Speech, and Signal Processing, 1993. ICASSP-93., 1993 IEEE International Conference on*. [S.l.], 1993. v. 3, p. 149–152. ISBN 0780309464.
- [Kashtiban, Razmi e Kozehkonan 2011] KASHTIBAN, A.; RAZMI, H.; KOZEHKONAN, M. Combined lvq neural network and multivariate statistical method employing wavelet coefficient for eeg signal classification. In: IEEE. *Mechatronics (ICM), 2011 IEEE International Conference on*. [S.l.], 2011. p. 809–814.
- [Kator e Legaz 2010] KATOR, A.; LEGAZ, J. *3D Models - Man in Suit (Armatured)*. 2010. Disponível em: <http://www.katorlegaz.com/3d_models/>.
- [Kiso e Seki 2010] KISO, A.; SEKI, H. Optimal mapping of torus self-organizing map for forearm motion discrimination based on emg. In: IEEE. *SICE Annual Conference 2010, Proceedings of*. [S.l.], 2010. p. 80–83.
- [Kohden 2011] KOHDEN, N. *Nihon Kohden Homepage*. 2011. Disponível em: <<http://www.nihonkohden.de>>. Acesso em: 29 out 2011.
- [Kohonen 1990] KOHONEN, T. The self-organizing map. *Proceedings of the IEEE*, IEEE, v. 78, n. 9, p. 1464–1480, 1990.
- [Kohonen 2001] KOHONEN, T. *Self-organizing maps*. 3. ed. [S.l.]: Springer-Verlag, 2001. 245–261 p.
- [König e Verschure 2002] KÖNIG, P.; VERSCHURE, P. F. M. J. Neurons in action. *Science*, American Association for the Advancement of Science, v. 296, n. 5574, p. 1817, 2002.

- [Kuribayashi et al. 1993] KURIBAYASHI, K. et al. A discrimination system using neural network for emg-controlled prostheses. In: IEEE. *Intelligent Robots and Systems' 93, IROS'93. Proceedings of the 1993 IEEE/RSJ International Conference on*. [S.I.], 1993. v. 3, p. 1750–1755.
- [Kyberd et al. 2001] KYBERD, P. J. et al. The design of anthropomorphic prosthetic hands: A study of the southampton hand. *Robotica*, Cambridge University Press, v. 19, n. 06, p. 593–600, 2001.
- [Lamounier et al. 2010] LAMOUNIER, E. et al. On the use of Virtual and Augmented Reality for upper limb prostheses training and simulation. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE*. [S.I.], 2010. p. 2451–2454. ISSN 1557-170X.
- [Li, Schultz e Kuiken 2010] LI, G.; SCHULTZ, A.; KUIKEN, T. Quantifying Pattern Recognition—Based Myoelectric Control of Multifunctional Transradial Prostheses. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, IEEE, v. 18, n. 2, p. 185–192, 2010. ISSN 1534-4320.
- [Li e Aruin 2005] LI, X.; ARUIN, A. Muscle activity onset time detection using teager-kaiser energy operator. In: IEEE. *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*. [S.I.], 2005. p. 7549–7552.
- [Li, Zhou e Aruin 2007] LI, X.; ZHOU, P.; ARUIN, A. Teager–kaiser energy operation of surface emg improves muscle activity onset detection. *Annals of Biomedical Engineering*, Springer, v. 35, n. 9, p. 1532–1538, 2007.
- [Light et al. 2002] LIGHT, C. M. et al. Intelligent multifunction myoelectric control of hand prostheses. *Journal of medical engineering & technology*, Informa Healthcare, v. 26, n. 4, p. 139–146, 2002.
- [Lima, Cunha e Landau 2010] LIMA, A.; CUNHA, G.; LANDAU, L. Utilização de recursos de realidade virtual na simulação off shore. *Revista Realidade Virtual*, UFRJ, v. 3, n. 2, p. 1–16, 2010.

- [Liu e Luo 2008] LIU, Z.; LUO, Z. Hand motion pattern classifier based on emg using wavelet packet transform and lvq neural networks. In: IEEE. *IT in Medicine and Education, 2008. ITME 2008. IEEE International Symposium on*. [S.I.], 2008. p. 28–32.
- [Lujan e Crago 2009] LUJAN, J.; CRAGO, P. Automated optimal coordination of multiple-dof neuromuscular actions in feedforward neuroprostheses. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 56, n. 1, p. 179–187, 2009.
- [Mar et al. 2011] MAR, T. et al. Optimization of ecg classification by means of feature selection. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 58, n. 8, p. 2168–2177, 2011.
- [Marks e Michael 2001] MARKS, L.; MICHAEL, J. Artificial limbs. *Bmj*, British Medical Journal Publishing Group, v. 323, n. 7315, p. 732, 2001.
- [Matsumura et al. 2002] MATSUMURA, Y. et al. Recognition system of emg patterns by neural networks. In: IEEE. *SICE 2002. Proceedings of the 41st SICE Annual Conference*. [S.I.], 2002. v. 3, p. 1613–1617.
- [Mattioli et al. 2009] MATTIOLI, F. et al. Uma proposta para o desenvolvimento Ágil de ambientes virtuais. In: SBC. *Anais do WRVA'2009*. Santos, 2009.
- [Mattioli et al. 2011] MATTIOLI, F. et al. Classification of emg signals using artificial neural networks for virtual hand prosthesis control. In: IEEE. *33rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC '11)*. Boston, 2011.
- [Mattioli et al. 2010] MATTIOLI, F. E. R. et al. Utilização de redes neurais para a classificação de sinais emg aplicados no controle de próteses virtuais de mão. In: SBC. *Anais WRVA'2010*. São Paulo, 2010. p. 230–235.
- [Mehrotra, Mohan e Ranka 1997] MEHROTRA, K.; MOHAN, C.; RANKA, S. *Elements of artificial neural networks*. [S.I.]: MIT Press, 1997.
- [Muceli, Jiang e Farina 2010] MUCELI, S.; JIANG, N.; FARINA, D. Multichannel surface emg based estimation of bilateral hand kinematics during movements at multiple degrees of freedom. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE*. [S.I.], 2010. p. 6066–6069.

- [MYOBOCK® System 2011] MYOBOCK® System. *SensorHand Speed Manual*. Minneapolis, MN, 2011.
- [Nielsen et al. 2009] NIELSEN, J. et al. Enhanced emg signal processing for simultaneous and proportional myoelectric control. In: IEEE. *Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE*. [S.l.], 2009. p. 4335–4338.
- [Nielsen et al. 2011] NIELSEN, J. et al. Simultaneous and proportional force estimation for multifunction myoelectric prostheses using mirrored bilateral training. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 51, n. 3, p. 681–688, 2011.
- [Nogueira 2007] NOGUEIRA, K. L. *O Uso de Técnicas de Realidade Virtual e Aumentada na Simulação de Prótese de Membros Superiores*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia, Julho 2007.
- [Nunes et al. 2007] NUNES, F. et al. *Aplicações Médicas usando Realidade Virtual e Realidade Aumentada*. [S.l.]: SBC, 2007. 223–255 p.
- [Okuno, Yoshida e Akazawa 2005] OKUNO, R.; YOSHIDA, M.; AKAZAWA, K. Compliant grasp in a myoelectric hand prosthesis. *Engineering in Medicine and Biology Magazine, IEEE*, IEEE, v. 24, n. 4, p. 48–56, 2005.
- [Peretta 2010] PERETTA, I. S. *A Speech Recognition System for Isolated Words With a Novel Word Boundaries Detector Based on Teager Energy Operator*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia, Dezembro 2010.
- [Plettenburg 2008] PLETTENBURG, D. The wilmer passive hand prosthesis for toddlers. In: *Proceedings of the 2008 MyoElectric Controls/Powered Prosthetics Symposium*. [S.l.: s.n.], 2008.
- [Pons et al. 2005] PONS, J. et al. Virtual reality training and EMG control of the MANUS hand prosthesis. *Robotica*, Cambridge University Press, v. 23, n. 03, p. 311–317, 2005.
- [Popescu et al. 2000] POPESCU, V. et al. A virtual-reality-based telerehabilitation system with force feedback. *Information Technology in Biomedicine, IEEE Transactions on*, IEEE, v. 4, n. 1, p. 45–51, 2000.

- [Qiu e Chen 2009] QIU, H.; CHEN, L. Real-time virtual military simulation system. In: IEEE. *Information Science and Engineering (ICISE), 2009 1st International Conference on*. [S.I.], 2009. p. 1391–1394.
- [Rossi, Carvalho e Soares 2008] ROSSI, A.; CARVALHO, A.; SOARES, C. Bio-inspired parameter tuning of mlp networks for gene expression analysis. In: IEEE. *Hybrid Intelligent Systems, 2008. HIS'08. Eighth International Conference on*. [S.I.], 2008. p. 435–440.
- [Russell e Norvig 2010] RUSSELL, S.; NORVIG, P. *Artificial intelligence: a modern approach*. Upper Saddle River, NJ, USA: Prentice Hall, 2010.
- [Sebelius et al. 2005] SEBELIUS, F. et al. Real-time control of a virtual hand. *Technology and Disability*, IOS Press, v. 17, n. 3, p. 131–141, 2005.
- [Soares et al. 2003] SOARES, A. et al. The development of a virtual myoelectric prosthesis controlled by an EMG pattern recognition system based on neural networks. *Journal of Intelligent Information Systems*, Springer, v. 21, n. 2, p. 127–141, 2003.
- [Sordi e Valdambrini 2006] SORDI, J. D.; VALDAMBRINI, A. Aplicabilidade da realidade virtual no desenvolvimento de protótipos: análise de sua utilização na volkswagen do brasil. In: ABEPRO. *Anais do Encontro Nacional de Engenharia de Produção - ENEGEP 2006*. [S.I.], 2006.
- [Su et al. 2007] SU, Y. et al. Towards an EMG-Controlled Prosthetic Hand Using a 3-D Electromagnetic Positioning System. *IEEE transactions on instrumentation and measurement*, p. 178–186, 2007.
- [Sun, Chen e Tian 2011] SUN, B.; CHEN, W.; TIAN, Y. The pattern recognition of surface emg based on wavelet transform and bp neural network. In: IEEE. *Proceedings of the 5th International Conference on Health Care Exchanges (PAHCE)*. [S.I.], 2011.
- [The Italian Tribune 2011] The Italian Tribune. *Italian Scientists Give Amputee Thought-Controlled Robotic Hand*. 2011. Disponível em: <<http://theitaliantribune.com/?p=119>>. Acesso em: 09 jun 2011.

- [Toledo et al. 2009] TOLEDO, C. et al. Upper limb prostheses for amputations above elbow: A review. In: IEEE. *Health Care Exchanges, 2009. PAHCE 2009. Pan American*. [S.I.], 2009. p. 104–108.
- [Tori e Kirner 2006] TORI, R.; KIRNER, C. *Fundamentos e tecnologia de Realidade Virtual e Aumentada*. Porto Alegre: Editora SBC, 2006. Fundamentos de Realidade Virtual.
- [Wang et al. 2009] WANG, B. et al. Comparison of different classification methods for eeg-based brain computer interfaces: A case study. In: IEEE. *Information and Automation, 2009. ICIA'09. International Conference on*. [S.I.], 2009. p. 1416–1421.
- [Weiss et al. 2004] WEISS, P. et al. Video capture virtual reality as a flexible and effective rehabilitation tool. *Journal of NeuroEngineering and Rehabilitation*, BioMed Central Ltd, v. 1, n. 1, p. 12, 2004.
- [Wolpaw e McFarland 2004] WOLPAW, J. R.; MCFARLAND, D. J. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy of Sciences of the United States of America*, The National Academy of Sciences of the USA, v. 101, n. 51, p. 17849, 2004.
- [Yang, Yantao e Yantao 2010] YANG, L.; YANTAO, T.; YANTAO, C. Multi-pattern recognition of sEMG based on improved BP neural network algorithm. In: IEEE. *Proceedings of the 29th Chinese Control Conference*. [S.I.], 2010. p. 2867–2872.
- [Yoh 2001] YOH, M. The reality of virtual reality. In: IEEE. *Virtual Systems and Multimedia, 2001. Proceedings. Seventh International Conference on*. [S.I.], 2001. p. 666–674.
- [Zecca et al. 2002] ZECCA, M. et al. Control of multifunctional prosthetic hands by processing the electromyographic signal. *Critical Reviews in Biomedical Engineering*, Citeseer, v. 30, n. 4-6, p. 459, 2002.
- [Zhou, Hansen e Kaiser 2001] ZHOU, G.; HANSEN, J.; KAISER, J. Nonlinear feature based classification of speech under stress. *Speech and Audio Processing, IEEE Transactions on*, IEEE, v. 9, n. 3, p. 201–216, 2001.