



UNIVERSIDADE DA BEIRA INTERIOR
Faculdade de Engenharia

Controlo de próteses multifuncionais através da simulação de sinais mioelétricos

Filipa Baptista Moreira

Dissertação para obtenção do Grau de Mestre em
**Engenharia Eletrotécnica e de Computadores no Ramo dos
Sistemas Biónicos**
(2º ciclo de estudos)

Orientador: Prof. Doutora Maria do Rosário Alves Calado

Covilhã, Outubro de 2015

Este documento foi produzido e organizado para ser apresentado como Dissertação em Engenharia Eletrotécnica e de Computadores no Ramo dos Sistemas Biónicos, cuja orientação científica foi da responsabilidade da Professora Dra. Maria do Rosário Alves Calado da Faculdade de Engenharia da Universidade da Beira Interior.

O conteúdo do presente trabalho, é da exclusiva responsabilidade do autor(a):

Assinatura:

Agradecimentos

À professora Dra. Maria do Rosário Alves Calado,

Pela orientação neste projeto. Muito obrigada pelo profissionalismo, pela sincera amizade e pela total disponibilidade que sempre revelou para comigo. Agradeço pelo entusiasmo e incentivo que sempre me transmitiu e pelas suas preciosas críticas e sugestões. O seu apoio foi determinante na elaboração desta Tese.

Ao Laboratório de Competências (LaC) da Faculdade de Ciências de Saúde, da Universidade da Beira Interior,

Por me ter proporcionado as condições necessárias para a elaboração da minha Tese.

À Inês,

Pela sua disponibilidade e colaboração em participar neste projeto.

À minha família, em especial aos meus Pais, à minha irmã e aos meus Avós,

Um enorme obrigada por acreditarem sempre em mim e naquilo que faço e por todos os ensinamentos de vida. Espero que esta etapa, que agora termino, possa, de alguma forma, retribuir e compensar todo o carinho, apoio e dedicação que, constantemente, me oferecem. A eles, dedico todo este trabalho.

Resumo

A amputação de um membro pode ter várias causas, nomeadamente acidentes de trabalho e viação, ferimentos por armas de fogo ou congelamento. A utilização de próteses difere consideravelmente em diferentes países. Este trabalho surgiu com o objetivo de se estudar o funcionamento das próteses mioelétricas.

De um voluntário do sexo feminino foram recolhidos os dados (sinais mioelétricos). Testaram-se dois movimentos: abrir e fechar a mão. Os dados foram obtidos através de elétrodos de superfície colocados sobre a pele do voluntário e ligados a um sistema eletrónico de aquisição adequado a sinais fisiológicos ("PowerLab/4st" da ADInstruments). Aos dados adquiridos foi posteriormente realizada a extração de características e a sua classificação.

Recorrendo ao software Matlab foi realizada a extração de ruído, a extração de características e a classificação dos sinais recolhidos.

Para a extração de ruído e extração de características do sinal foi utilizada a Wavelet Packet Toolbox que aplicava a Transformada Wavelet Packet.

Para a classificação foram estudadas e comparadas duas técnicas de classificação: Redes Neurais e Máquinas de Vetores de Suporte. Para isso foram utilizadas a Neural Pattern Recognition Toolbox e Classification Learner Toolbox, respetivamente.

O classificador de Redes Neurais utiliza um vetor de target (vetor constituído apenas por zeros e uns) para classificar o sinal. O classificador de Máquinas de Vetores de Suporte utiliza um modelo de classificação para classificar os sinais. Comparando os dois classificadores, a Máquina de Vetores de Suporte apresenta melhores resultados relativamente ao classificador das Redes Neurais.

Palavras-chave

Eletromiografia, Próteses Mioelétricas, Elétrodos, Transformada Wavelet Packet, Redes Neurais, Máquinas de Vetores de Suporte.

Abstract

The amputation of a limb can have various causes, including work and traffic accidents, injuries by firearms or freezing. The use of prosthetics differs significantly in different countries. This work was meant to study the operation of myoelectric prostheses.

Data (myoelectric signals) was taken from a female volunteer. Two movements were tested: open and close the hand. Data were obtained through surface electrodes placed on the skin of voluntary and linked to an electronic system suitable acquisition physiological signs ("PowerLab/4st" of ADInstruments).

Using the Matlab software was performed the noise extraction, feature extraction and classification of the collected signals.

For the noise and features extraction was used Wavelet Packet Toolbox that applied the Wavelet Packet Transform (WPT).

For classification was studied and compared two classification techniques: Neural Networks and Support Vector Machines (SVM). For this was used Neural Pattern Recognition Toolbox and Classification Learner Toolbox, respectively.

The Neural Network classifier uses a target vector (vector only consists of zeros and ones) to classify the signal. The Support Vector Machine classifier uses a classification model to classify the signs. Comparing the two classifiers, the Support Vector Machine performs better relative to the Neural Network classifier.

Keywords

Electromyography, Myoelectric Prostheses, Electrodes, Wavelet Packet Transform, Neural Networks, Support Vector Machines

Índice

1	Introdução	1
1.1	O Sistema Muscular	1
1.1.1.	Estrutura do Músculo Esquelético	2
1.1.2.	Fisiologia do Músculo Esquelético	4
1.1.2.1.	Junção Neuromuscular	4
1.1.2.2.	Acoplamento Excitação - Contração	6
1.1.2.3.	Tipos de contração muscular	8
1.2.	Eletromiografia	9
1.2.1.	Os elétrodos	9
1.2.2.	Método de aquisição e processamento do sinal EMG	11
1.3.	Próteses	12
1.3.1.	Próteses não-funcionais ou passivas	13
1.3.2.	Próteses não funcionais ou ativas	14
1.3.2.1.	Próteses mioelétricas	15
1.4.	Wavelets	16
1.4.1.	Famílias Wavelet	17
1.4.2.	Transformada de Wavelet	19
1.4.3.	Transformada Wavelet Packet	19
1.5.	Algoritmos de aprendizagem de máquinas	21
1.5.1.	Redes Neurais	22
1.5.2.	Máquinas de Vetores de Suporte	24
2.	Estado da Arte em próteses mioelétricas	28
2.1.	iLimb Ultra, da Touch Bionics	28
2.2.	Bebionic, da SRL Steeper	29
2.3.	Michelangelo, da Otto Bock	30
3.	Trabalho Prático	31
3.1.	Materiais	31
3.2.	Procedimentos e Métodos	32
3.2.1.	Aquisição dos dados	32
3.2.2.	Condicionamento do sinal	34
3.2.3.	Reconhecimento de padrões	35
3.2.3.1.	Extração de características	35
3.2.3.2.	Classificação	36
3.2.3.2.1.	Redes Neurais	36
3.2.3.2.2.	Máquina de Vetores de Suporte	37

4.	Resultados	38
5.	Conclusão	43
6.	Bibliografia	44
	ANEXO A - Gráficos dos sinais recolhidos durante a aquisição de dados para cada um dos movimentos	49
	ANEXO B - Código Matlab para o condicionamento do sinal e gráficos dos sinais após o condicionamento do sinal	56
	ANEXO C - Código em Matlab para a extração de características	65
	ANEXO D - Código em Matlab para os classificadores	67

Índice de Figuras

Figura 1.1 – Fibras musculares esqueléticas em secção longitudinal [1]	2
Figura 1.2 - Partes de um músculo [1]	2
Figura 1.3 - Junção Neuromuscular [1]	4
Figura 1.4 - Libertação de ACh em resposta a um potencial de ação na junção neuromuscular [1]	5
Figura 1.5 - Túbulos T e Retículo Sarcoplasmático [1]	6
Figura 1.6 - Processo dos potenciais de ação e contração muscular [1]	7
Figura 1.7 - Despolarização e repolarização do potencial de ação [1]	8
Figura 1.8 - Aquisição e processamento de um sinal mioelétrico utilizando um eletromiógrafo [4]	12
Figura 1.9 - Prótese não-funcional ou passiva utilizada em pacientes com amputação parcial da mão e do braço [10]	14
Figura 1.10 - Diagrama de blocos de um dispositivo de uma prótese mioelétrica [12]	16
Figura 1.11 - Função Haar [18]	17
Figura 1.12 - Família Daubechies [18]	18
Figura 1.13 - Família Coiflet [18]	18
Figura 1.14 - Família Symmlet [18]	18
Figura 1.15 - Decomposição de um sinal x , resultando nos coeficientes de aproximação e de detalhe, utilizando a Transformada de Wavelet [17]	19
Figura 1.16 - Árvore de decomposição com 4 níveis de decomposição [15]	20
Figura 1.17 - Arquitetura de uma Rede Neuronal multi-camada [22]	24
Figura 1.18 - Mapeamento de um hiperplano não-linear e linear [25]	25
Figura 1.19 - Arquitetura de uma Máquina de Vetores de Suporte [22]	27
Figura 2.1 - Exemplos de próteses de mãos multiarticulares existentes comercialmente: a) iLimb Ultra da Touch Bionics Inc.; b)Bebionic V1, da RSL Steeper	28
Figura 2.2 - Componentes da mão prótica i-Limb Ultra, da Touch Bionics [30]	29
Figura 2.3 - Mão prótica Bebionic e Bebionic V2, ambas da SRL Steeper [31]	29
Figura 2.4 - Mão prótica Michelangelo da Otto Bock [31]	30
Figura 3.1 - Representação dos músculos escolhidos para a aquisição dos sinais mioelétricos: a) Músculo extensor detalhado (muitas referências consideram-no como um único músculo); b) Músculo flexor comum [1]	32
Figura 3.2 - Representação do equipamento PowerLab com o cabo Bio Amp [3]	33
Figura 3.3 - Ligação do transdutor MLT003/D ao PowerLab na entrada pod1 [3]	33
Figura 3.4 - Atividade EMG do paciente	34
Figura 4.1 - Arquitetura da Rede Neuronal criada pelo classificador	38

Figura 4.2 - Matriz de Confusão do classificador de Redes Neuronais	39
Figura 4.3 - Curvas ROC do classificador Redes Neuronais	40
Figura 4.4 - Modelo de Validação criado pelo classificador Máquinas de Vetores de Suporte	41
Figura 4.5 - Resultados obtidos após a utilização da função <i>predict</i>	42

Lista de Tabelas

Tabela 1.1 - Tipos de Wavelets [17]	17
Tabela 1.2 - Funções Kernel utilizadas nas Máquinas de Vetores de Suporte [22]	26

Lista de Acrónimos

ACh	Acetilcolina
Ca ²⁺	ião de Cálcio
EMG	Eletromiografia
WP	Wavelet Packet
BP	Back Propagation
LaC	Laboratório de Competências
CH1	Canal 1
CH2	Canal 2
WPT	Wavelet Packet Transform
SVM	Support Vector Machines
ROC	Receiving Operating Characteristic

1.Introdução

1.1.O Sistema Muscular

A maior parte dos movimentos do corpo resultam da contração muscular. As principais funções dos músculos são: movimento corporal (andar, correr, manipular objetos), manutenção da postura (permite-nos ficar sentados ou em pé), respiração (os músculos do tórax são responsáveis pelos movimentos necessários à respiração), produção de calor corporal (da contração dos músculos esqueléticos resulta calor), comunicação (falar, escrever à mão ou à máquina, gestos, expressão facial), constrição de órgãos e vasos (deslocação dos alimentos e água ao longo do tubo digestivo e regulação de fluxo nos vasos sanguíneos) e batimento cardíaco (contração do músculo cardíaco que provoca o batimento cardíaco e bombeia o sangue para todas as partes do corpo). [1]

O músculo tem quatro características funcionais fundamentais: contractilidade, excitabilidade, extensibilidade e elasticidade. A contractilidade designa a capacidade que o músculo tem de se contrair, produzindo uma determinada força. Excitabilidade é a capacidade que o músculo tem para responder a um estímulo. Extensibilidade significa que o músculo pode ser estirado até ao seu comprimento normal em repouso e, em certo grau, para lá desse comprimento. A elasticidade significa que, depois de serem estirados, os músculos retornam ao seu comprimento original em repouso. [1]

Existem três tipos de tecidos musculares: músculo-esquelético, músculo liso e músculo cardíaco. O músculo-esquelético está inserido nos ossos, é formado por células muito longas e cilíndricas (1-40 mm de comprimento, podendo-se estender a todo o comprimento dos pequenos músculos; 10-100 µm de diâmetro), é estriado, é controlado de forma voluntária e involuntária (reflexos), não contém capacidade de contração espontânea e a sua principal função é o movimento corporal. O músculo liso está inserido nas paredes dos órgãos ocos, vasos sanguíneos, olhos, glândulas e pele, as suas células têm a forma de fusos (15-200 µm de comprimento e 5-10 µm de diâmetro, não é estriado, alguns músculos têm a capacidade de contração espontânea e as suas principais funções são a mobilização dos alimentos no tubo digestivo, esvaziamento da bexiga, regulação do diâmetro dos vasos sanguíneos, alteração do tamanho da pupila, contração de muitos canais glandulares e movimento dos pelos. O músculo cardíaco é o próprio coração, as suas células têm forma cilíndrica e são ramificadas (100-500 µm de comprimento; 100-200 µm de diâmetro), é estriado, o controlo é involuntário, tem capacidade de contração espontânea e a sua principal função é bombear o sangue (as contrações constituem a principal força para impulsionar o sangue nos vasos sanguíneos). [1, 2]

1.1.1. Estrutura do Músculo Esquelético

Os músculos-esqueléticos são compostos por fibras musculares esqueléticas, associadas a pequenas quantidades de tecido conjuntivo, vasos sanguíneos e nervos. As fibras musculares esqueléticas são células musculares esqueléticas. Cada fibra muscular esquelética é uma célula cilíndrica única que contém diversos núcleos localizados à periferia da fibra, junto da membrana celular, tal como mostra a figura 1.1. [1, 2]

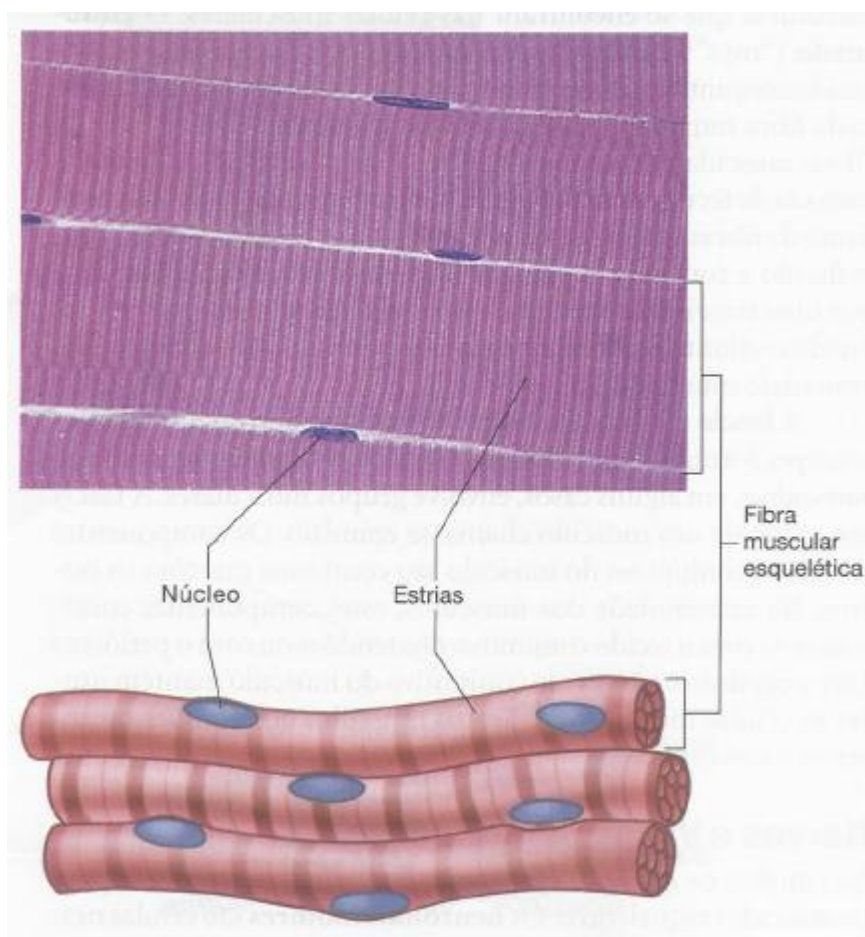


Figura 1.1 - Fibras musculares esqueléticas em secção longitudinal [1]

Como se observa na figura 1.1, numa secção longitudinal, a alternância de bandas claras e escuras dá à fibra muscular um aspeto estriado. Uma fibra única pode-se estender de uma extremidade à outra de um músculo pequeno, mas são necessárias diversas fibras, dispostas topo a topo, para preencher toda a extensão da maioria dos músculos mais longos. As fibras musculares têm comprimentos que vão de 1 a 40 mm e diâmetros de 10 a 100 μm . Os músculos grandes contêm fibras de grande diâmetro, enquanto que os músculos pequenos e mais delicados têm fibras de pequeno diâmetro. Todas as fibras musculares de um mesmo músculo têm dimensões similares. [1]




Figura 1.2 - Partes de um músculo [1]

Envolvendo cada fibra muscular existe uma delicada lâmina externa composta, sobretudo, por fibras reticulares. Esta lâmina externa é produzida pela fibra muscular e, quando observada ao microscópio óptico, não se consegue distinguir da membrana da fibra muscular. Esta lâmina externa tem o nome de sarcolema. [1]

São muitos os nervos e vasos sanguíneos que se estendem para os músculos esqueléticos. Os neurónios motores são células nervosas especializadas. Os seus corpos celulares localizam-se no tronco cerebral ou na medula espinhal e os axónios estendem-se até às fibras musculares esqueléticas através dos nervos. Os neurónios motores estimulam a contração muscular. O contacto entre os axónios e as fibras musculares tem o nome de sinapse ou junção neuromuscular. Cada neurónio motor inerva mais do que uma fibra muscular e cada fibra muscular recebe um ramo de um axónio. [1]

Na figura 1.2 é possível identificar as miofibrilhas que preenchem as fibras musculares. Cada miofibrilha é uma estrutura filamentosa, com um diâmetro aproximado de 1 a 3 μm , que se estende de uma extremidade do músculo para a outra. As miofibrilhas são compostas por duas espécies de filamentos proteicos chamadas miofilamentos. Os miofilamentos de actina, ou miofilamentos finos, têm aproximadamente 8 nanômetros de diâmetro e 1000 nm de comprimento, e os miofilamentos de miosina, ou miofilamentos grossos, têm cerca de 12 nm de diâmetro e 1800 nm de comprimento. [1, 2]

1.1.2. Fisiologia do músculo esquelético

1.1.2.1. Junção Neuromuscular

Os axônios dos neurônios motores transportam potenciais de ação, a alta velocidade, do encéfalo e medula espinhal para as fibras musculares esqueléticas. Os axônios ramificam-se repetidamente e cada ramo projeta-se para uma única fibra muscular para a inervar. Assim, cada fibra muscular recebe o ramo de um axônio e cada axônio inerva mais de uma fibra muscular. [1]

Junto de cada fibra que inerva, cada ramo axonal forma um terminal nervoso alargado que se aloja numa invaginação do sarcolema formando uma sinapse, ou junção neuromuscular. Cada axônio acaba no terminal pré-sináptico. O espaço entre este e a fibra muscular é a fenda sináptica e a membrana da célula muscular na área de junção é a membrana pós-sináptica. Na figura 1.3 podemos observar um diagrama que mostra a junção neuromuscular. [1]

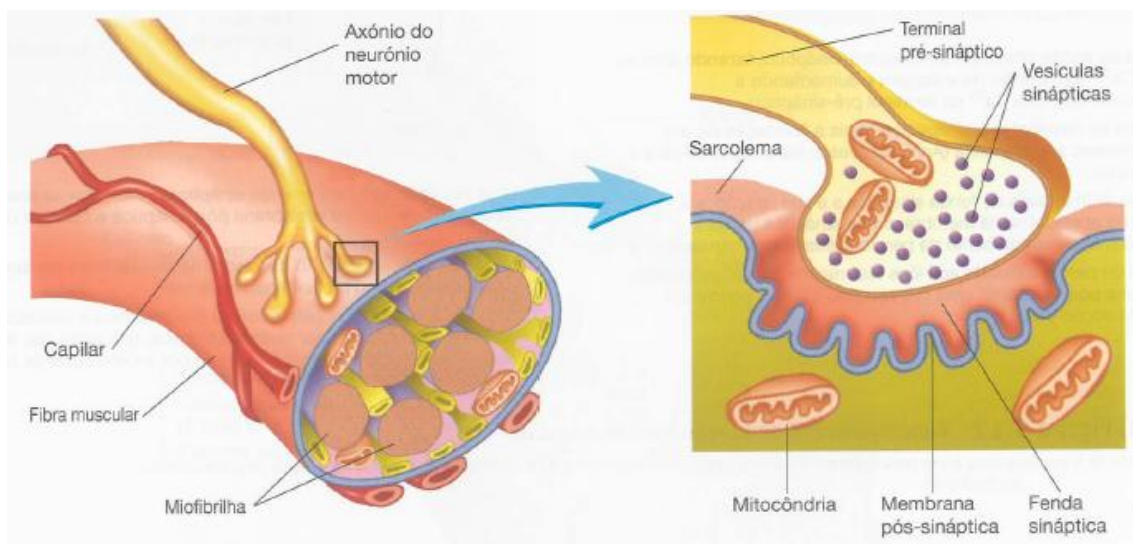


Figura 1.3 - Junção Neuromuscular [1]

Cada terminal pré-sináptico contém dentro da sua membrana muitas vesículas esféricas com cerca de 45 μm de diâmetro, chamadas de vesículas sinápticas. As vesículas contêm acetilcolina (ACh), molécula orgânica composta de ácido acético e colina, que atua como

neurotransmissor. Um neurotransmissor é uma substância libertada por uma membrana pré-sináptica, que se difunde através de uma fenda sináptica e estimula (ou inibe) a produção de um potencial de ação na membrana pós-sináptica. [1, 2]

Na figura 1.4 podemos observar que quando o potencial de ação atinge o terminal pré-sináptico provoca a abertura de canais de cálcio (Ca^{2+}) na membrana celular do axónio, o que leva à difusão dos iões Ca^{2+} para dentro da célula. Uma vez dentro da célula, os iões Ca^{2+} provocam a secreção do conteúdo de diversas vesículas sinápticas, por exocitose, do terminal pré-sináptico para o interior da fenda sináptica. As moléculas de acetilcolina libertadas das vesículas sinápticas difundem-se, depois, através da fenda e ligam-se a moléculas recetoras localizadas na membrana pós-sináptica. Isto leva à abertura de canais Na^+ , aumentando a permeabilidade da membrana aos iões de sódio (Na^+). O Na^+ difunde-se então para dentro da célula, produzindo a despolarização da membrana. No músculo-esquelético, cada potencial de ação no neurónio motor causa uma despolarização que excede o limiar, resultando na produção de um potencial de ação na fibra muscular. [1, 2]




Figura 1.4 - Libertação de ACh em resposta a um potencial de ação na junção neuromuscular [1]

A acetilcolina libertada para a fenda sináptica é rapidamente desdobrada em ácido acético e colina pela enzima acetilcolinesterase. A acetilcolinesterase evita que a acetilcolina se acumule na fenda sináptica, onde atuaria como um estímulo constante no terminal pós-sináptico. A libertação de acetilcolina e a sua rápida degradação na fenda sináptica asseguram que um potencial de ação pré-sináptico produza apenas um potencial de ação pós-sináptico. As moléculas de colina são ativamente reabsorvidas pelo terminal pré-sináptico e combinam-se, então, com o ácido acético produzido na célula, de modo a formar acetilcolina. [1]

1.1.2.2. Acoplamento Excitação - Contração

O mecanismo pelo qual um potencial de ação leva à contração da fibra muscular chama-se acoplamento excitação-contração. O sarcolema tem ao longo da sua superfície, muitas invaginações tubulares chamada túbulos T. Os túbulos T, que podem ser observados na figura 1.5, projetam-se para dentro das fibras musculares e enrolam-se em torno dos sarcómeros, na região onde os miofilamento de actina e miosina se sobrepõem. Suspenso no sarcoplasma, entre os túbulos T, está o retículo sarcoplásmico. [1, 2]




Figura 1.5 - Túbulos T e Retículo Sarcoplasmático [1]

Em repouso, as diferenças de potencial através das membranas das células nervosas e das fibras musculares estão à volta de -85 mV. Esta diferença de potencial traduz-se num número negativo porque a superfície interior da membrana está a um potencial inferior ao do exterior. [1, 2]

O acoplamento excitação-contração começa na junção neuromuscular, com a produção de um potencial de ação no sarcolema. O potencial de ação propaga-se ao longo de todo o sarcolema da fibra muscular. Quando o potencial de ação atinge os túbulos T, as membranas destes sofrem despolarização, porque os túbulos T são invaginações do sarcolema. Os túbulos T transportam a despolarização para o interior da fibra muscular. Esta despolarização leva à abertura dos canais Ca^{2+} . Durante a fase de despolarização, o potencial de membrana altera-se de cerca de -85 mV para +20 mV. Quando os canais Ca^{2+} do retículo sarcoplásmico abrem, os iões Ca^{2+} difundem-se rapidamente do retículo sarcoplásmico para o sarcoplasma que rodeia as miofibrilhas. Este processo pode ser observado a figura 1.6. [1, 2]




Figura 1.6 - Processo dos potenciais de ação e contração muscular [1]

Na figura 1.6 vemos ainda que os íons Ca^{2+} ligam-se à troponina dos miofilamentos de actina. Esta ligação expõe os locais ativos dos miofilamentos de actina. Estes locais ativos expostos ligam-se às moléculas de miosina. Esta ligação leva à contração muscular. [1, 2]

A contração muscular é o encurtamento de um músculo em resposta a um estímulo que causa um potencial de ação em uma ou mais fibras musculares. O aumento da frequência dos potenciais de ação numa fibra muscular esquelética, aumenta também a frequência das contrações. [1]

Após ocorrer a contração muscular o potencial de membrana é resposto. Durante esta fase de repolarização do potencial de repouso, o potencial de membrana altera a sua carga, alterando o seu potencial de cerca de +20 mV para -85 mV. [1, 2]

A figura 1.7 ilustra o gráfico com a curva de despolarização e repolarização do potencial de ação. [1]

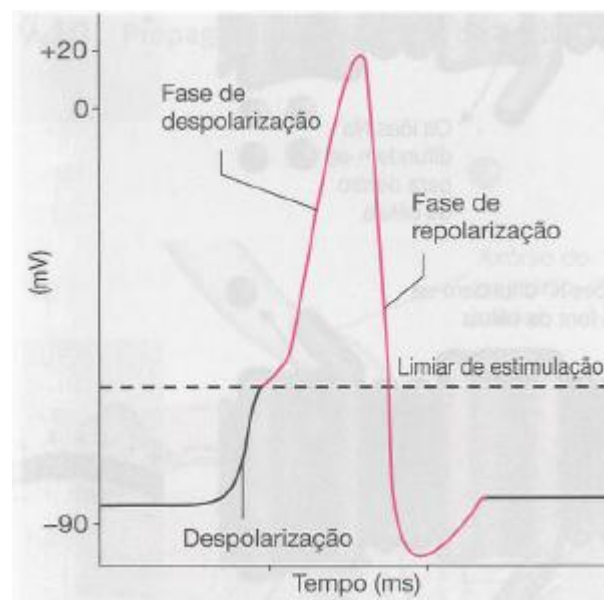


Figura 1.7 - Despolarização e repolarização do potencial de ação [1]

1.1.2.3. Tipos de Contração Muscular

As contrações musculares classificam-se com base no tipo de contração predominante. [1, 2]

Nas contrações isométricas o comprimento do músculo não se altera, mas aumenta a quantidade de tensão durante o processo de contração. As contrações isométricas são responsáveis pelo comprimento constante dos músculos posturais do corpo, como os músculos que mantêm a coluna vertebral direita quando nos sentamos ou estamos em pé. [1, 2]

Nas contrações isotônicas, a quantidade de tensão produzida pelo músculo é constante durante a contração, mas o comprimento do músculo altera-se. Os movimentos dos braços e dos dedos das mãos são predominantemente contrações isotônicas. Exemplos deste tipo de contração incluem o acenar com a mão ou usar um teclado de computador. A maior parte das contrações musculares não são estritamente isométricas nem isotônicas. Por exemplo, quer o comprimento, quer a tensão dos músculos alteram-se quando uma pessoa anda ou abre uma porta pesada. Embora haja algumas diferenças mecânicas, ambos os tipos de contração resultam do mesmo processo contrátil nas células musculares. [1, 2]

Contrações concêntricas são contrações isotônicas nas quais a tensão do músculo é suficientemente grande para vencer a resistência que se lhe opõe, resultando no comprimento do músculo. As contrações concêntricas incluem as contrações que resultam numa tensão crescente à medida que o músculo se encurta. Uma grande percentagem dos movimentos executados pelas contrações musculares consiste em contrações concêntricas. [1, 2]

Contrações excêntricas são contrações isotônicas em que a tensão é mantida, mas a resistência que se lhe opõe é tal que o músculo aumenta de comprimento. As contrações excêntricas são executadas quando uma pessoa deixa descer lentamente um peso grande. Durante as contrações excêntricas, os músculos desenvolvem uma força substancial. [1, 2]

1.2. Eletromiografia

Uma característica essencial dos animais é a sua capacidade para se movimentar no ambiente circundante. Os atuadores de movimento são os músculos cujas contrações geram forças sobre os segmentos do esqueleto ao qual eles estão ligados. Além de propriedades mecânicas, a atividade dos músculos esqueléticos é também associada com a geração de sinais elétricos que podem ser registados por elétrodos inseridos nos músculos (intramuscular) ou fixados sobre a pele (superfície). Os sinais elétricos gerados pelos músculos durante a sua atividade são referidos como sinais de eletromiografia (EMG). [3, 4]

Uma contração muscular voluntária é produzida por um ou mais potenciais de ação em várias fibras. A atividade EMG não é uma série regular de ondas, mas sim um sinal caótico que resulta da sobreposição de sinais de pico. [3, 4]

1.2.1. Os elétrodos

Para adquirir os sinais mioelétricos é utilizado um conjunto de elétrodos diretamente na superfície da pele ou então são colocados de forma intramuscular estando diretamente em contacto com os músculos. [4, 5, 6]

Eléttodos intramusculares podem ser de agulha ou fio. Em se tratando de músculos profundos ou pequenos, utilizam-se eléctodos de fio ou de agulha, pois esses possuem uma pequena área de detecção e são limitados nos estudos de unidades motoras. Para análise das unidades motoras, utilizam-se eléctodos de agulha, pois possuem menor área de detecção, embora sejam críticos em atividades de contração forçada ou por influência considerável de dor. [4]

Um eléctrodo de superfície é constituído por um material condutor, com dimensões e forma definida, que é ligado eletricamente à pele do paciente, e mantido no lugar por meio de um método de fixação de fita adesiva apropriada. Os materiais normalmente utilizados no fabrico dos eléctodos são a prata sólida ou ouro, prata sintetizada e cloreto de prata, carbono e esponja saturada com gel eletrólito ou hidrogéis condutores. Os eléctodos de superfície podem ser combinados com matrizes mono e bidimensionais para fornecer informação de múltiplos canais e para implementar a filtragem espacial, a fim de melhorar a seletividade da gravação. As matrizes costumam utilizar barras de prata-cloreto de prata e não são adequadas para gravações a longo prazo ou em condições não isométricas. [4, 5, 6]

O sinal EMG pode ser adquirido, não necessariamente por um simples eléctrodo, mas pode resultar de uma combinação dos sinais vindos de vários eléctodos, podendo, deste modo, ser classificado como monopolar, bipolar ou multipolar. [4]

A configuração monopolar é grandemente utilizada quando se adquire um sinal simples e associada a este, se faz a necessária utilização de um eléctrodo de referência, estando este bastante afastado do eléctrodo ativo para evitar perturbações no sinal adquirido. Este tipo de configuração monopolar é normalmente utilizado em análises gerais do sinal EMG, quando o objetivo é comparar a morfologia interna e sinais externos ou mesmo, quando o músculo é muito pequeno ou estreito em configurações bipolares. [4]

Eléttodos com uma configuração bipolar são os mais utilizados em estudos que envolvem contração voluntária, ou sob condições de estimulação elétrica. Para esta configuração o sinal é detetado em dois locais. Qualquer sinal que é comum a ambos os locais é eliminado, e os sinais que são diferentes aos dois locais são amplificados. [4]

Os eléctodos podem ainda ser passivos ou ativos. Os eléctodos passivos não possuem amplificação no próprio eléctrodo. Este tipo de eléctrodo apenas deteta o sinal EMG e envia para um amplificador. Os eléctodos ativos realizam a amplificação do sinal detetado. Estes eléctodos possuem um pré-amplificador que subtrai e amplifica o sinal EMG, tornando, desta forma, o ruído vindo dos cabos menos significativo. [4, 5]

Quando o metal entra em contacto com o eletrólito, existem dois fenómenos que controlam a gravação do sinal através de eléctodos:

1. O metal atrai íons positivos ou negativos (dependendo da eletroquímica dos dois) a partir do eletrólito, na superfície do eletrodo. Os íons complementares estão agrupados um pouco mais afastados do eletrodo na direção do eletrólito de modo a que entre os dois grupos exista um pequeno espaço neutro;
2. O metal tem tendência a libertar íons metálicos no eletrólito deixando um excesso de eletrões livres, semelhante ao processo de corrosão. [5]

As duas interações eletroquímicas dão origem a uma camada de dipolo de carga que atua como um condensador. A camada de dipolo é a impedância da fonte de sinal de entrada de EMG do músculo para o eletrodo. [5]

1.2.2. Método de aquisição e processamento do sinal EMG

O sinal EMG é adquirido por um eletromiógrafo. Um eletromiógrafo, ilustrado na figura 1.8, é geralmente constituído por um amplificador de EMG com vários canais, uma placa de aquisição incorporada ou externa e um computador equipado com software para visualização de sinal, aquisição, avaliação offline e às vezes de processamento. [4]

Durante a amplificação e filtragem do sinal, normalmente é utilizado um filtro passa-banda, com o objetivo de reduzir os artefactos de movimento (filtro passa-alto) e o ruído (filtro passa-baixo). No filtro passa-baixo a frequência de corte varia entre 250 e os 500 Hz. Para o filtro passa-alto a frequência de corte varia entre 0,1 e os 100 Hz. No entanto, é importante ter em atenção que este filtro também pode eliminar algumas informações importantes presentes no sinal EMG. [7]

Geralmente quando aplicamos os eletrodo na pele coloca-se um gel eletrólito entre estes dois com o objetivo de se facilitar a troca entre cargas entre os eletrólitos e a pele, melhorando assim a aquisição dos dados (biopotenciais). [4, 5]

O eletrodo vai funcionar como um transdutor lendo os potenciais de aquisição do EMG. Os eletrodos mais utilizados são não invasivos e são os eletrodos passivos para EMG. [4, 5]

O amplificador deve ter um ganho elevado e deve ter a capacidade de isolar o sinal de interesse de todo o ruído que o envolve. [4, 7]

O sinal EMG de superfície pode ter frequências até cerca de 400 a 500 Hz. A frequência máxima é afetada por fatores como por exemplo o tipo de unidade motora e contração, tamanho do eletrodo e distância entre eletrodos e músculos, portanto, normalmente considera-se como frequência de amostragem mínima para o sinal de EMG superficial da ordem dos 1000 Hz ou até mais. [4, 7]




Figura 1.8 - Aquisição e processamento de um sinal mioelétrico utilizando um eletromiógrafo [4]

Os valores registados variam dependendo do tipo de contração, do tamanho do músculo ou de outras diferenças técnicas ou metodológicas. Contrações isométricas podem atingir amplitudes de 5 mV pico a pico para medições de superfície. Medições intramusculares não são atenuadas pelo tecido podendo atingir um máximo de 10 mV. O valor máximo de amplitude de pico (30 mV) é geralmente associado a potenciais evocados. [5]

A propagação de corrente através do tecido muscular é dependente da frequência. Com o aumento da frequência, há uma diminuição na amplitude do sinal gravado pelos elétrodos. Sendo esta uma atenuação progressiva da amplitude do sinal de alta frequência, o músculo atua como um filtro passa-baixo. [5]

1.3. Próteses

Próteses são utensílios utilizados para substituir uma região perdida ou malformada do nosso organismo, restaurando a aparência e a função natural dessa mesma região. No entanto não

faz sentido falar em próteses sem que antes se entenda o conceito de amputação, pois é esta que gera a necessidade do estudo e desenvolvimento das próteses. [6, 8]

Amputação consiste na extração, geralmente cirúrgica, total ou parcial de um membro. As causas mais frequentes das amputações são traumáticas (acidentes de trabalho, acidentes de viação e explosivos), tumorais, cirúrgicas ou ainda devido a anomalias genéticas. [6, 8, 9]

O membro residual da amputação é denominado por coto. O coto de amputação, agora considerado como um novo membro, é responsável pelo controlo da prótese durante a apreensão, percepção, comunicação e atividades laborais. Para que isso seja possível, é necessário que o coto seja estável, tenha a pele em bom estado, com boa sensibilidade, sem úlceras e enxerto cutâneo, ter uma boa circulação arterial e venosa, boa cicatrização e ausência de edema. [8]

As próteses podem ser classificadas de acordo com a sua ação funcional e as suas fontes de energia. [10]

De acordo com a sua ação funcional são classificadas em próteses não funcionais ou passivas: estéticas; e em próteses funcionais ou ativas: mecânicas ou com fonte de energia interna, próteses com fontes de energia externa e próteses híbridas. [10]

De acordo com as suas fontes de energia são classificadas em sistemas endoenergéticos ou de propulsão muscular e em sistemas exoenergéticos ou de propulsão artificial. Nos sistemas endoenergéticos ou de propulsão muscular a energia é originada no próprio corpo do paciente, transmitindo-se esta energia através de cabos para o dispositivo terminal. Nos sistemas exoenergéticos ou de propulsão artificial a energia é originada externamente ao corpo e não depende da transmissão via cabos. Existe ainda o sistema híbrido que resulta da combinação dos dois sistemas citados anteriormente. [10]

1.3.1. Próteses não-funcionais ou passivas

As próteses não funcionais ou passivas envolvem as próteses estéticas. Estas próteses restabelecem o aspeto externo, sem proporcionar funções ativas, favorecendo o aspeto estético. Neste tipo de próteses são grandes as exigências em relação ao aspeto externo, conforto de utilização e peso reduzido. [10]

As próteses não funcionais são geralmente semi-móveis ou totalmente imóveis. Devido ao facto de serem utilizadas somente por razões estéticas, podem ser utilizadas em todos os níveis de amputação. A figura 1.9 mostra uma prótese passiva para amputação parcial da mão e do braço, oferecendo um aspeto natural à zona de amputação. [10]



Figura 1.9 - Prótese não-funcional ou passiva utilizada em pacientes com amputação parcial da mão e do braço [10]

Este tipo de prótese é mais leve que as próteses funcionais e é descrita como a mais confortável. A desvantagem na utilização desta prótese está no facto de necessitar de uma reposição manual, movendo-a com o braço oposto, não podendo assim restaurar a função do braço amputado. [6]

1.3.2. Próteses funcionais ou ativas

As próteses funcionais ou ativas são acionadas pelo próprio paciente. Para coordenar as diferentes funções, o paciente precisa de um intenso programa de treino, com o objetivo de adquirir, de forma progressiva, o controlo dos diferentes movimentos da prótese. [1]

As próteses funcionais ou ativas subdividem-se em: próteses mecânicas ou com fonte de energia interna (próteses ativadas pelo movimento do corpo), próteses com fontes de energia externa e próteses híbridas. [10]

Nas próteses mecânicas a energia origina-se no próprio corpo do paciente (sistema endoenergético) transmitindo-se através de cabos para o dispositivo terminal. É utilizado um cinto de segurança e um sistema de cabos para fornecer ação funcional ao membro. O movimento voluntário do membro estende-se ao cabo que transmite a força para o dispositivo terminal. Apesar da vantagem na possibilidade de ação funcional, alguns pacientes queixam-se devido ao desconforto da sua utilização. Outras desvantagens são a temperatura gasta no sistema e a aparência pouco atraente. [6, 10]

Nas próteses com fonte de energia externa (sistema exoenergético), a energia origina-se externamente ao corpo do paciente (energia extracorpórea), sendo normalmente utilizadas baterias para o efeito. Estas próteses são controladas pelo movimento de estruturas naturais remanescentes ou através da atividade eletromiográfica fornecida por um grupo muscular escolhido. [10]

As próteses híbridas resultam da junção dos dois sistemas anteriormente citados, ou seja contém uma fonte de energia interna e outra externa. É normalmente utilizado para

amputações de alto nível (igual ou superior ao cotovelo). Os sistemas híbridos permitem o controlo de duas articulações de uma só vez e são geralmente mais leves e menos caros do que uma prótese constituída apenas por componentes de sistemas exoenergéticos. [6, 10]

Idealmente uma prótese deve ser controlada sem que se exija qualquer esforço por parte do utilizador, e seja ainda similar ao controlo subconsciente de um membro natural. No entanto, esse facto não acontece devido às limitações ainda existentes nas próteses até então desenvolvidas. [8]

1.3.2.1. Próteses mioelétricas

As próteses mioelétricas são acionadas por motores elétricos com uma fonte de alimentação externa. Este tipo de prótese é recomendada para pacientes incapazes de utilizar dispositivos que funcionam pela energia do próprio corpo. [5, 6]

Ao contrário dos dispositivos que funcionam pela energia do próprio corpo, um dispositivo mioelétrico opera a prótese por controlo elétrico, fornecendo movimentos muito mais precisos. As próteses mioelétricas são baseadas na medição da atividade mioelétrica dos músculos que permanecem no coto após a amputação. A atividade muscular no coto, pode ser utilizada para controlar alguns movimentos pré-definidos da prótese. [5, 6]

Para medir a atividade dos músculos do coto podem ser utilizados elétrodos invasivos e não invasivos. No entanto, os elétrodos não invasivos são geralmente os mais utilizados. Os elétrodos são colocados na cavidade da prótese, estando em permanente contacto com o coto, adquirindo a atividade elétricas dos músculos. [5, 6]

A utilização de uma matriz de elétrodos aumenta o grau de adaptação da prótese com relativamente baixo custo. O número máximo de elétrodos colocados é limitado pela área de superfície do coto. Cada ação muscular provoca um potencial elétrico específico que é recebido por uma determinada área da matriz de elétrodos. [5]

Os sinais EMG gerados a partir da contração muscular são detetados pelos elétrodos. No entanto, após a aquisição do sinal, o sinal oferece-nos informações importantes mas de uma forma particularmente inútil. Esta informação é útil apenas se o sinal poder ser quantificado. O sinal é então enviado para o bloco de condicionamento de sinal, onde ocorre a amplificação, filtragem e conversão A/D do sinal. [5, 7, 11]

Com a conversão do sinal analógico num sinal digital, obtêm-se sinais de saída PWM. [5, 7, 11]

No desenvolvimento de próteses mioelétricas, a informação sobre a intenção dos sinais EMG adquiridos pode ser estudada no domínio do tempo ou no domínio da frequência. [12, 13, 14]

Nos últimos anos, têm sido utilizados vários métodos de extração de características para reconhecimento de padrões, como por exemplo o valor médio absoluto, o número de cruzamentos de zeros, o número de mudanças na inclinação do sinal, o comprimento de onda, a média da inclinação do valor absoluto, a amplitude de Wilson, a variância, a raiz quadrada média, o histograma, os coeficientes autorregressivos, os coeficientes da Transformada de Fourier Rápida, os coeficientes de Cepstrum, os coeficientes da Transformada de Wavelet e os coeficientes do Pacote da Transformada de Wavelet. [12, 13, 14]

Podem ser utilizadas várias abordagens para classificar as características extraídas para identificar o movimento pretendido. Algumas formas de classificação utilizadas são por exemplo a Análise Discriminante Linear, o K-Vizinho mais próximo, as Redes Neurais, os sistemas Fuzzy, os classificadores Neuro-Fuzzy, e as Máquinas de Vetores de Suporte. [12, 13, 14]

A figura 1.10 mostra o diagrama de blocos de uma prótese mioelétrica que permite entender a integração dos sistemas eletrônicos e mecânicos e os problemas relativos ao reconhecimento de padrões. [12]

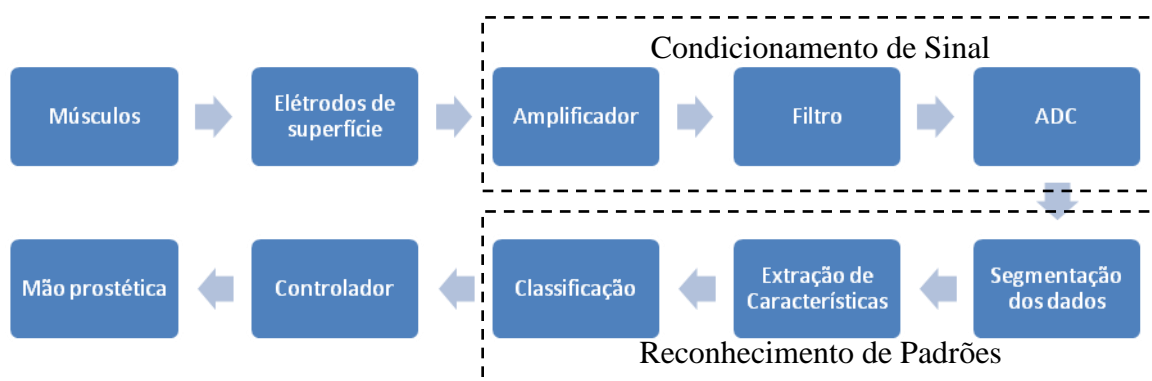


Figura 1.10 - Diagrama de blocos de um dispositivo de uma prótese mioelétrica [12]

1.4. Wavelets

A análise de Fourier, sendo muitas vezes utilizada, tem a desvantagem de que a informação transitória é perdida no domínio da frequência. Isto pode ser melhorado utilizando a Transformada de Fourier de curto tempo, no entanto alguma informação poderá ser perdida em frequências muito baixas ou muito altas. [15, 16]

A principal vantagem da Transformada de Wavelet em relação à Transformada de Fourier ou à Transformada de Fourier de curto tempo é a janela de tempo-frequência ser flexível e adaptar-se de tal modo que existe sempre o mesmo número de períodos da frequência

analisada na janela de tempo. A análise de Wavelet permite a utilização de longos intervalos de tempo para informações mais precisas de baixa frequência e regiões mais curtas para a informação de frequência mais alta. [15, 16, 17]

A transformação Wavelet é alcançada pela quebra acima de um sinal em versões deslocadas e escalonadas da Wavelet original. Wavelets são capazes de determinar se existe um sinal transitório rápido, e se assim for, pode localizá-lo. Esta característica faz com que as Wavelets sejam muito úteis para o estudo das formas de onda EMG. [15]

1.4.1. Famílias Wavelet

As Wavelets podem ser divididas em ondas discretas ou contínuas. As contínuas podem ser divididas em reais e complexas. No entanto, as Wavelets mais utilizadas são as discretas. A tabela 1.1 mostra os diferentes tipos de Wavelet. [17]

Wavelets Discretas	Wavelets Contínuas	
Tipo	Tipo (Reais)	Tipo (Complexas)
Coiflet	Beta	Mexican Hat
Daubechies	Hermitian	Morlet
Haar	Mexican Hat	Modified Morlet
Symmlet	Shannon	Shannon

Tabela 1.1 - Tipos de Wavelets [17]

A família Haar é a forma mais simples de Wavelet. É uma Wavelet compacta, ortogonal e simétrica, mas é descontínua. Esta Wavelet representa o mesmo que a Wavelet Daubechies db1. A função Haar está representada na figura 1.11. [17, 18]




Figura 1.11 - Função Haar [18]

A família Daubechies é uma família de Wavelets ortogonais que definem a Transformada de Wavelet Discreta. Os nomes da família Daubechies são escritos na forma dbN, onde N é a ordem e db é o sobrenome da wavelet. A família db1, tal como dito acima, é o mesmo que a wavelet Haar. A figura 1.12 mostra as funções wavelet dos próximos 9 membros da família. [17, 18]




Figura 1.12 - Família Daubechies [18]

Coiflet é uma família wavelet projetada para ser mais simétrica do que a família Daubechies. É construída usando uma função de escalonamento e uma função wavelet. A função wavelet tem $2N$ momentos iguais a zero e a função de escalonamento tem $2N-1$ momentos iguais a zero. A figura 1.13 mostra a família Coiflet. [17, 18]




Figura 1.13 - Família Coiflet [18]

Symmlet é uma família de ondas compactas, ortogonais, contínuas e quase simétricas. Foram propostas como modificações à família Daubechies, sendo as propriedades das duas famílias bastante semelhantes. A figura 1.14 mostra a família Symmlet. [17, 18]




Figura 1.14 - Família Symmlet [18]

1.4.2. Transformada de Wavelet

Na Transformada de Wavelet os sinais são divididos em detalhe e aproximação. A aproximação obtida a partir do primeiro nível é dividida num novo detalhe e uma nova aproximação e este processo é repetido. Devido ao facto de a Transformada de Wavelet decompor apenas as aproximações do sinal, isto pode trazer alguns problemas ao utilizá-la em certas aplicações em que a informação mais importante está localizada nos componentes de frequência mais elevada. A figura 1.15 mostra a decomposição de um sinal utilizando a Transformada de Wavelet. [15, 17, 18]

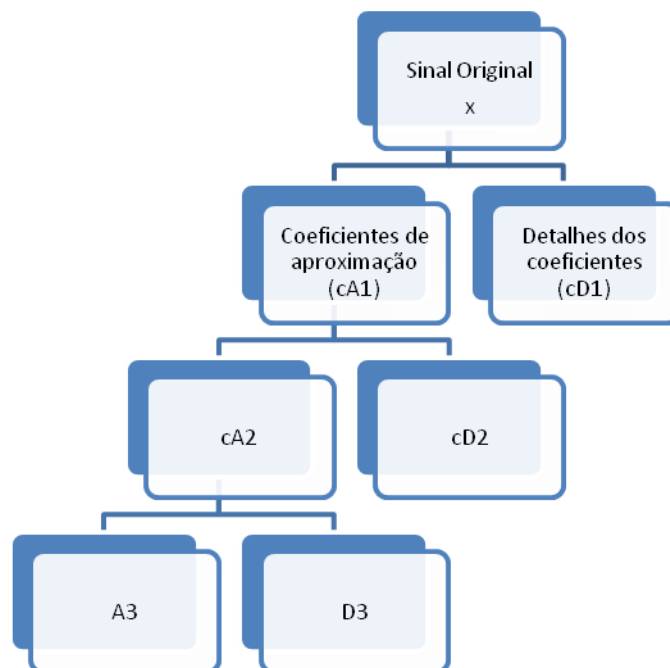


Figura 1.15 - Decomposição de um sinal x , resultando nos coeficientes de aproximação e de detalhe, utilizando a Transformada de Wavelet [17]

1.4.3. Transformada Wavelet Packet

A análise Wavelet Packet (WP) é uma expansão da decomposição Wavelet clássica que apresenta mais possibilidades de processamento de sinais. A principal diferença entre a Transformada de Wavelet e a Transformada de Wavelet Packet é que na Transformada Wavelet Packet não apenas as aproximações são decompostas como também os detalhes. Assim, com a utilização da Transformada Wavelet Packet, pode ser obtida uma melhor resolução de frequência para o sinal decomposto. Além disso, a utilização da Transformada Wavelet Packet extrai muito mais características sobre o sinal. Para o nível de decomposição n , o segmento do sinal bruto é dividido como mostra a figura 1.16. [15, 17, 18]

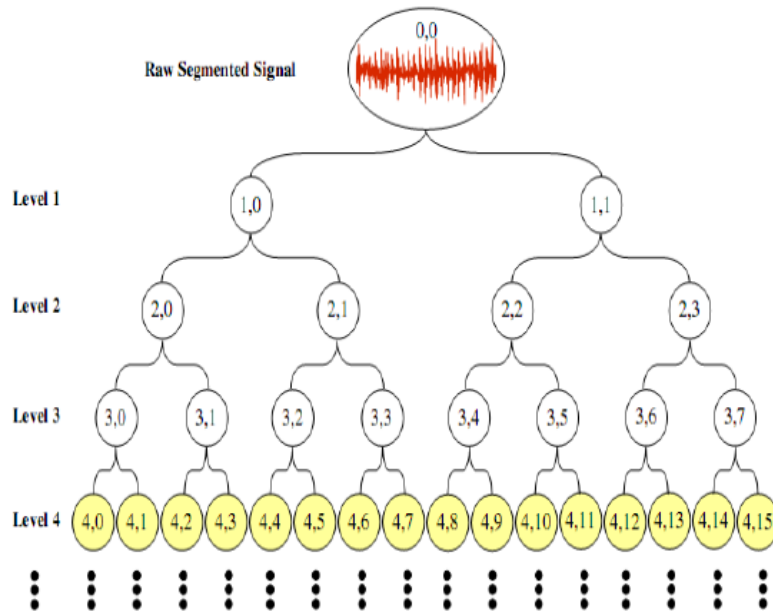


Figura 1.16 - Árvore de decomposição com 4 níveis de decomposição [15]

Uma Wavelet Packet é uma função com três índices de números inteiros i , j e k que representam os parâmetros de modulação, escala e translação, respectivamente:

$$\Psi_{j,k}^i(t) = 2^{j/2} \Psi^j(2^j t - k), \quad i = 1, 2, 3, \dots \quad (1)$$

As funções Wavelet Ψ^j são determinadas a partir das seguintes equações recursivas:

$$\Psi^{2j}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} h(k) \Psi^j(2t - k) \quad (2)$$

$$\Psi^{2j+1}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} g(k) \Psi^j(2t - k) \quad (3)$$

O sinal original $f(t)$ após j níveis de decomposição é definido como:

$$f(t) = \sum_{i=1}^{2^j} f_j^i(t) \quad (4)$$

enquanto a componente de sinal Wavelet Packet $f_j^i(t)$ é demonstrada por uma combinação linear de funções Wavelet Packet $\Psi_{j,k}^i(t)$:

$$f_j^i(t) = \sum_{-\infty}^{\infty} c_{j,k}^i(t) \Psi_{j,k}^i(t) \quad (5)$$

onde os coeficientes Wavelet Packet $c_{j,k}^i(t)$ são calculados por:

$$c_{j,k}^i(t) = \int_{-\infty}^{\infty} f(t) \Psi_{j,k}^i(t) dt \quad (6)$$

desde que as funções Wavelet Packet satisfaçam a ortogonalidade:

$$\Psi_{j,k}^m(t) \Psi_{j,k}^n(t) = 0 \quad \text{se } m \neq n \quad (7)$$

A energia E_n de uma Wavelet Packet $\Psi_{j,k}^i(t)$ é dada por:

$$E_k = \sum_{-\infty}^{\infty} |c_{j,k}^i(t)|^2 \quad (8)$$

Para se normalizar a energia de uma Wavelet Packet , divide-se a energia pela energia total do sinal:

$$NE_{j,k} = \frac{E_k}{E} \times 100\% \quad (9)$$

Onde E é a energia total do sinal dada por:

$$E = \sum_{-\infty}^{\infty} E_n \quad (10)$$

1.5. Algoritmos de aprendizagem de máquinas

Os algoritmos de aprendizagem são métodos adaptativos por unidades de computação de rede auto-organizadas para perceber o comportamento desejado. A aprendizagem de máquinas baseia-se em aprender a prever a partir de amostras de comportamentos desejados ou de observações passadas de dados. Os algoritmos de aprendizagem de máquinas dividem-se em: aprendizagem supervisionada, aprendizagem não supervisionada, aprendizagem semi-supervisionada, aprendizagem por reforço e aprendizagem indutiva. [19]

Na aprendizagem supervisionada o algoritmo cria uma função que faz o mapeamento dos dados para direcionar as saídas. O aprendizado compara então a sua resposta real ao alvo e

ajusta a sua memória interna de tal modo que aumenta a probabilidade de ser produzida a resposta correta da próxima vez que o algoritmo receber a mesma entrada. [19]

Na aprendizagem não supervisionada (clustering, redução de dimensionalidade, sistemas de recomendação, aprendizagem auto-organizada) é modelada um conjunto de entradas. Não há saídas alvo, ou seja, não há quaisquer exemplos rotulados. O aprendiz não recebe feedback de ambiente. [19]

Na aprendizagem semi-supervisionada o algoritmo cria exemplos marcados e não marcados e uma função especial. [19]

A aprendizagem por reforço é aprender através da interação com o ambiente. O aprendiz recebe o feedback sobre a adequação da sua resposta. [19]

Na aprendizagem indutiva o algoritmo aprende a sua tendência indutiva baseado na sua experiência prévia. [19]

1.5.1. Redes Neurais

As Redes Neurais são um método de aprendizagem de máquinas supervisionado. O algoritmo das Redes Neurais é formado por células que simulam as funções de baixo nível dos neurónios biológicos. O conhecimento sobre o problema é distribuído em neurónios com pesos das conexões das ligações entre os neurónios. A Rede Neuronal tem de ser treinada para ajustar os pesos e os desvios das ligações, a fim de produzir o mapeamento desejado. Na fase de treino, os vetores de características são aplicados como entrada para a rede e a rede ajusta as suas variáveis de parâmetro, os pesos e tendências, para captar a relação entre os padrões de entrada e de saída. As Redes Neurais são particularmente úteis para tarefas de reconhecimento e classificação de padrões complexos. A capacidade de aprendizagem a partir de exemplos, a capacidade de reproduzir funções não lineares arbitrárias de entrada e a estrutura altamente paralela e regular, torna as Redes Neurais especialmente adequadas para tarefas de classificação de padrões. [7, 19, 20, 21, 22]

Os requisitos para a conceção de uma Rede Neuronal para uma dada aplicação incluem: (i) a determinação da arquitetura da rede; (ii) a definição do número total de camadas, o número de unidades escondidas nas camadas médias e número de unidades nas camadas de entrada e saída; (iii) o algoritmo de treino durante a fase de aprendizagem. [20, 22, 23]

Existem várias arquiteturas para as Redes Neurais, nomeadamente a arquitetura de realimentação e a arquitetura das redes recorrentes. A rede neuronal mais popular é a Perceptron multi-camada, que é uma rede de realimentação e frequentemente explorada nos

sistemas de reconhecimento de padrões. Este tipo de rede é caracterizado por um conjunto de entradas, uma camada de unidades de saída e um certo número de camadas escondidas. Cada nó de entrada é conectado a cada unidade da camada escondida. Entre todas as arquiteturas, as redes de realimentação multi-camadas treinados com o algoritmo *Back Propagation* (BP) parece ser o método mais importante e amplamente utilizado no reconhecimento de padrões de movimentos de mãos protéticas. [7, 15, 24]

A figura 1.17 mostra uma arquitetura típica de uma Rede Neuronal multi-camada, com três camadas: uma camada de entrada, uma camada oculta e uma camada de saída. [22]

Uma rede *Back Propagation* é uma rede adaptativa cujos nós (neurónios) realizam a mesma função em sinais de entrada. A entrada x de um nó é descrita como a soma ponderada dos sinais de entrada mais um termo de polarização. A entrada e saída de um nó j são dadas pela equação 11 e pela equação 12, respetivamente:

$$x_j = \sum_i w_{i,j} x_i + w_j \quad (11)$$

$$x_j = f(x_j) = \frac{1}{1 + \exp(-x_j)} \quad (12)$$

onde x_i é a saída do conjunto de nós i em cada uma das camadas anteriores, $w_{i,j}$ é o peso relativo para os elos de ligação i e j , e w_j é o tendência do nó j . [24]

Uma rede *Back Propagation* (BP) pode ser definida como se segue. Em primeiro lugar, uma medida do erro quadrado para o par p entrada-saída é:

$$E_p = \sum_k (d_k - x_k)^2 \quad (13)$$

onde d_k é a saída pretendida para o nó k e x_k é a saída atual para o nó k como parte de entrada do par de dados p apresentado. A fim de encontrar o vetor de gradiente, um termo de erro ε_i é definido como:

$$\varepsilon_i = \frac{\partial E_p}{\partial x_i} \quad (14)$$

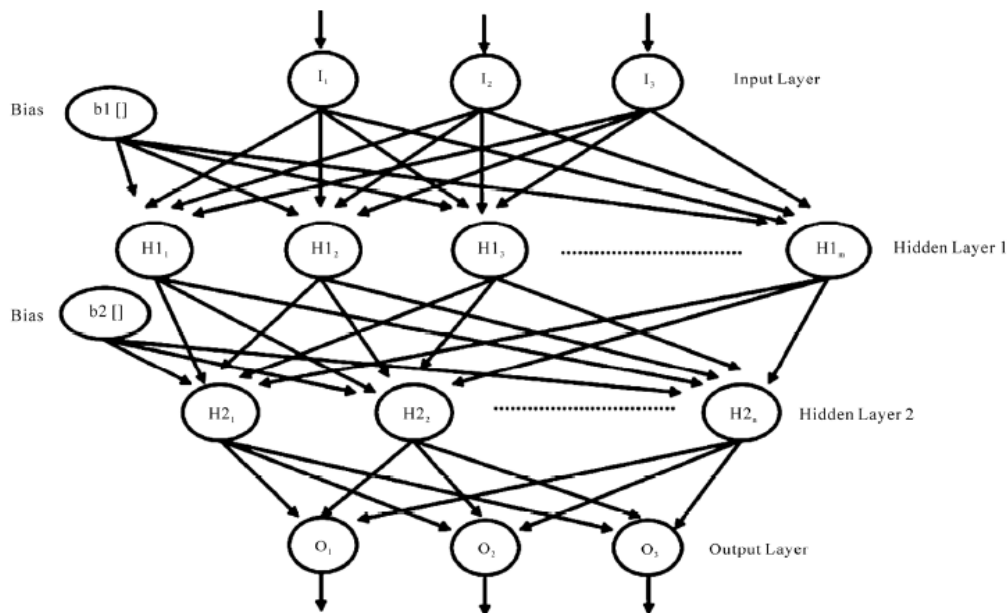


Figura 1.17 - Arquitetura de uma Rede Neuronal multi-camada [22]

1.5.2. Máquinas de Vetores de Suporte

As Máquinas de Vetores de Suporte são também um método de aprendizagem de máquinas supervisionado. As Máquinas de Vetores de Suporte fazem o mapeamento dos vetores de entrada \mathbf{x} no espaço de características de alta dimensão \mathcal{Z} através de algum mapeamento não linear, escolhido antecipadamente. Neste espaço é construído um hiperplano de separação. [22]

As Máquinas de Vetores de Suporte é um classificador binário $f: R^N \mapsto \{\pm 1\}$ que é estimado a partir de dados empíricos:

$$(x_1, y_1), \dots, (x_m, y_m) \in R^N \times \{\pm 1\} \quad (15)$$

Para um problema de classificação não linear a solução é dada pelo mapeamento dos dados originais no espaço de características, em que os dados mapeados são separados de forma linear por um hiperplano tal como na figura 1.18. [25, 26]




Figura 1.18 - Mapeamento de um hiperplano não-linear e linear [25]

Para uma classificação não linear, um espaço de características de dimensão não-linear, constrói um classificador:

$$w \cdot \varphi(x) + b = 0 \quad (16)$$

O hiperplano não só separa corretamente duas classes de pontos de dados, mas também faz uma margem máxima (distância do ponto mais perto do hiperplano). Aplicando a Transformada de Lagrange, a função de classificação é:

$$f(x) = \text{sgn}\left(\sum_{i=1}^l a_i^* y_i K(x, x_i) + b\right) \quad (17)$$

onde x_i é o vetor de treino, x é o vetor de reconhecimento e a_i^* é o operador de Lagrange. [14, 22, 26, 27]

A função de Kernel é dada por:

$$K(x, x_i) = \varphi(x_i) \cdot \varphi(x) \quad (18)$$

As funções Kernel proporcionam um método conveniente para obter as características de elevada dimensão, mapeadas a partir dos dados sem calcular a transformação não linear. As funções de Kernel comuns são a linear, a quadrática, a polinomial e a de base radial. A Tabela 1.2 mostra as diferentes funções Kernel. [14, 22]

Função Kernel	Equação
Linear	$K(x, x_i) = x \cdot x_i$
Quadrática	$K(x, x_i) = (x \cdot x_i + 1)^2$
Polinomial	$K(x, x_i) = (x \cdot x_i + 1)^q$
Base Radial	$K(x, x_i) = \exp x - x_i ^2/\sigma^2$

Tabela 1.2 - Funções Kernel utilizadas nas Máquinas de Vetores de Suporte [22]

Nas Máquinas de Vetores de Suporte o treino é reformulado e representado de forma a obter-se um problema de programação quadrática. A solução para este problema é global e única. Nesta aproximação é possível escolher vários tipos de funções Kernel. [25]

Existem vários hiperplanos possíveis que separem os dados, mas existe apenas um único hiperplano com uma margem máxima de separação entre classes. Para construir este hiperplano ótimo é necessário resolver-se o seguinte problema de programação quadrática:

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i y_i (w\phi(x_i) + b) \geq 1 \quad i = 1, 2, \dots, m \quad (19)$$

A Máquina de Vetores de Suporte é uma ferramenta poderosa em classificação binária, capaz de gerar funções de classificação muito rápidas na sequência de um período de treino. Existem várias abordagens para a adoção das Máquinas de Vetores de Suporte para problemas com três ou mais classes (problemas multi-classes) $f: R^N \mapsto \{1, \dots, k\}$ que estima qual a classe mais adequada após se fornecerem dados empíricos:

$$(x_1, y_{x_1}), \dots, (x_k, y_{x_k}) \in R^N \times \{1, \dots, k\} \quad (20)$$

As abordagens utilizadas são: método de classificação “one-against-all” ou OAA e método de classificação “one-against-one” ou OAO. [13, 14, 22, 25]

No método de classificação OAA, para se classificar uma nova amostra, são utilizados k classificadores que trabalham separadamente e é escolhido aquele que gera um maior valor da função de decisão como classe estimada. Este esquema é de fácil implementação e relativamente rápido. Produz melhores resultados que os outros métodos. [22, 25]

No método de classificação OAO, $k(k-1)$ classificadores binários são treinados separadamente para separar um par de duas classes. Para classificar uma nova amostra, a classe que tem mais votos dos classificadores binários é escolhida como resultado final. Este método pode ser implementado e é também um método rápido como o método OAA. A vantagem deste método relativamente ao método OAA é que conduz as classificações binárias em todos os pares de classes e calcula a probabilidade de cada classe. [22, 25]




Figura 1.19 - Arquitetura de uma Máquina de Vetores de Suporte [22]

A figura 1.18 mostra a arquitetura de uma Máquina de Vetores de Suporte. [22]

Uma propriedade importante das Máquinas de Vetores de Suporte é que esta estimação de parâmetro de modelo corresponde a um problema de otimização convexa o que significa que qualquer solução local será uma ótimo global. As Máquinas de Vetores de Suporte são também adequadas para dados ocultos. São bem-sucedidas quando aplicadas em sinais biológicos para reconhecimento de padrões. [14]

2. Estado da Arte em Próteses Mioelétricas

Desde o final da década de 1960, tem sido possível a utilização de um cotovelo de potência com uma mão alimentada, e mais tarde de um pulso de potência com uma mão alimentada, em conjunto, no que é chamado de prótese multifuncional. Durante a última década, várias mãos antropomórficas multiarticulares foram introduzidas, duas delas ilustradas da figura 2.1. Ambos os avanços tecnológicos têm levado à necessidade de sistemas de controlo mais sofisticados, capazes de controlar múltiplas funções. [28, 29]

A fim de explorar plenamente as possibilidades dessas novas próteses multifuncionais, é necessário um controlo melhor e mais intuitivo. A complexidade e a falta de robustez nos sistemas de controlo de hoje em dia podem ser as razões pelas quais as pessoas ainda utilizam próteses acionadas pela energia do próprio corpo. [28, 29, 30]




Figura 2.1 - Exemplos de próteses de mãos multiarticulares existentes comercialmente: a) iLimb Ultra da Touch Bionics Inc.; b) Bebionic V1, da RSL Steeper

2.1. iLimb Ultra, da Touch Bionics

A i-Limb Ultra da Touch Bionics é uma mão protética inovadora, sendo considerada atualmente a mais versátil do mercado. [30, 31]

A i-Limb Ultra é composta por dedos em que cada um se movimenta de forma independente, ou seja, cada um está individualmente alimentado e cada um tem um motor separado que os faz movimentar-se. A i-Limb Ultra é controlada pelo utilizador que ao pensar em abrir e fechar a mão aciona certos músculos. O acionamento desses músculos gera um impulso elétrico. Este impulso elétrico é captado pelo sensor, um eléctrodo que é colocado no membro residual, e é enviado para o computador da prótese. A mão vai abrir ou fechar com base nos músculos que são acionados e geram certos impulsos. Em seguida, os dedos são abertos ou fechados pelo computador. Os dedos também dobram as articulações naturais fazendo a prótese ainda mais realista. Estes componentes são mostrados na figura 2.2. [30]



Figura 2.2 - Componentes da mão próstética i-Limb Ultra, da Touch Bionics [30]

A i-Limb Ultra permite ao utilizador realizar as suas atividades diárias como se tivesse as duas mãos. O movimento individual dos dedos da mão próstética permite uma melhor aderência, sendo útil para o utilizador. A i-Limb Ultra pode ser cara, mas também não oferece totalmente a mão amputada de volta ao utilizador. Pode por vezes exigir algum pré-posicionamento e por essa razão não é considerada uma mão próstética perfeita. Ainda assim esta prótese pode ajudar muitos amputados na sociedade de hoje em dia. [30]

2.2. Bebionic, da SRL Steeper

A mão próstética Bebionic que está na figura 2.3 é muito semelhante em construção à mão i-Limb da Touch Bionics. A mão próstética Bebionic foi produzida pela RSL Steeper com a intenção de oferecer uma funcionalidade semelhante à i-Limb a um preço ligeiramente mais reduzido. Esta mão baseia-se diretamente na mão i-Limb da Touch Bionics utilizando exatamente os mesmo componentes mecânicos. Existem poucas ou nenhuma diferença funcionais entre as duas mãos próstéticas, sendo então consideradas iguais para fins de discussão. [31]



Figura 2.3 - Mão próstética Bebionic e Bebionic V2, ambas da SRL Steeper [31]

2.3. Michelangelo, da Otto Bock

A mão prótica Michelangelo na figura 2.4 é a mais avançada do mercado hoje em dia. Infelizmente a mão tem um preço de 100000\$, sendo muito difícil a sua aquisição. Esta mão prótica é muito mais completa, tendo ao contrário da mão i-Limb e da mão Bebionic, o dedo polegar alimentado, tornando-se muito mais semelhante a uma mão natural. [31]



Figura 2.4 - Mão prótica Michelangelo da Otto Bock [31]

3.Trabalho Prático

O objetivo deste trabalho prático é estudar o funcionamento das próteses mioelétricas multifuncionais, estudando e comparando os resultados de duas técnicas de classificação: Redes Neurais e Máquinas de Vetores de Suporte.

3.1.Materiais

A aquisição dos sinais mioelétricos foi realizada no Laboratório de Competências (LaC) da Faculdade de Ciências de Saúde, da Universidade da Beira Interior. A amostra era composta apenas por um indivíduo do sexo feminino de 22 anos de idade, saudável e sem qualquer tipo de amputação e ausência de doenças neuromusculares conhecidas. [3, 32, 33]

O indivíduo deveria ter ainda a pele em boas condições e livre de quaisquer produtos como cremes e perfumes. O indivíduo voluntário para esta experiência deveria ainda utilizar roupa confortável e retirar quaisquer adereços como relógios e pulseiras. [3, 33]

Os músculos escolhidos para fazer a aquisição dos sinais localizam-se no antebraço e são denominados por músculo extensor dos dedos (localizado na parte exterior do antebraço, serve para abrir a mão) e por músculo flexor dos dedos (localizado na parte interior do antebraço, serve para fechar a mão), ver figura 3.1. [1, 3, 33]

Com recurso ao sistema de aquisição de sinais “PowerLab/4st” da ADInstruments, ligado a um computador no qual o software LabChart foi instalado, foi possível realizar a recolha dos dados digitalmente. Salienta-se que a recolha dos dados decorreu no mês de Fevereiro

Após a recolha dos dados foi utilizado o software Matlab para realizar o condicionamento dos sinais recolhidos e realizar a extração de características dos sinais e a sua classificação.




Figura 3.1 - Representação dos músculos escolhidos para a aquisição dos sinais mioelétricos:
 a) Músculo extensor detalhado (muitas referências consideram-no como um único músculo);
 b) Músculo flexor comum [1]

3.2. Procedimentos e Métodos

3.2.1. Aquisição dos dados

No início da experiência o “PowerLab/4st” está ligado a um computador. Em seguida liga-se o cabo Bio Amp, que possui 5 derivações, na unidade PowerLab, ver figura 3.1. [3]

O cabo Bio Amp permite a ligação de cinco elétrodos. Um ligado à Terra, dois ligados ao canal 1 (CH1) positivo e negativo e dois ligados ao canal 2 (CH2) positivo e negativo, ver figura 3.2. [3]

O elétrodo Terra vai ligar ao exterior do pulso do voluntário. Este elétrodo serve como referência a todos os outros elétrodos. Os dois elétrodos ligados a CH1 vão ligar ao músculo flexor dos dedos na parte interior do antebraço. Estes elétrodos devem estar colocados a uma distância entre 2 e 5 cm um do outro. Os dois elétrodos ligados a CH2 vão ligar ao músculo extensor dos dedos, na parte exterior do antebraço, separados também por uma distância de 2 a 5 cm um do outro. Para esta experiência, a polaridade dos elétrodos não influencia nos resultados mas os canais devem estar corretos. [3, 33]



Figura 3.2 - Representação do equipamento PowerLab com o cabo Bio Amp [3]

Entre os eléctrodos e a pele do voluntário deverá colocar-se um gel eletrólito. Será utilizada fita adesiva para segurar os eléctrodos na pele do voluntário. [3]

Em seguida é ligado o transdutor MLT003/D ao PowerLab na entrada pod 1, de acordo com a figura 3.3. [3]

O voluntário deverá estar sentado numa posição relaxada, com o cotovelo apoiado numa mesa e dobrado a 90° com a palma da mão virada para cima. Na mão do braço onde estão a ser realizadas as medições deverá segurar o transdutor MLT003/D, como mostra a figura 3.3. [3]




Figura 3.3 - Ligação do transdutor MLT003/D ao PowerLab na entrada pod1 [3]

É criado um novo projeto no LabChart. No canal 2 mede-se a força exercida pelo voluntário ao apertar o transdutor, ver figura 18. O canal 2 é configurado para modo diferencial e é ajustada a amplitude (o transdutor apresenta uma saída linear igual a 2.37mV/Kg). Coloca-se a taxa de amostragem a 200/s. Abre-se a caixa de diálogo Input Amplifier dialog e define-se em: Range 200 mV, AC Coupled checkbox off, Low Pass 50Hz, Positive and Negative checkboxes on, Invert checkbox off. [3]

Para começar a aquisição de dados pressiona-se o botão “Start”. Durante alguns segundos o voluntário deverá fazer os movimentos de abrir e fechar a mão, tendo em atenção que quando fecha a mão deverá apertar o transdutor MLT003/D. [3]

Nos canais 3 e 4 observam-se os sinais medidos para fechar e abrir a mão, respetivamente, ver figura 3.4. [3]

Por fim dever-se-á parar a aquisição de dados carregando no botão “Stop”. [3]




Figura 3.4 - Atividade EMG do paciente

A aquisição dos dados gera um ficheiro de texto com os valores dos sinais obtidos. Para cada movimento são seleccionados 6 frames para se proceder à extração das suas características e classificação. [34]

3.2.2. Condicionamento do sinal

Durante a aquisição do sinal, os eléctrodos recolhem sinais a partir de diferentes unidades motoras, o que provoca um aumento do ruído do sinal. Para remover o ruído dos sinais adquiridos recorreu-se ao método de Wavelet. Este método é preferível à filtragem no domínio da frequência, pois mantém as características do sinal enquanto reduz o ruído. [35]

A decomposição Wavelet Packet é uma transformada Wavelet onde o sinal de tempo discreto (amostra) é passado através de vários filtros. Para n níveis de decomposição a WPD produz 2n conjuntos diferentes de coeficientes ou nós. [35]

Recorrendo às funções da Wavelet Toolbox do software Matlab, é possível realizar o condicionamento do sinal retirando-lhe o ruído. [18, 35]

Como parâmetros de análise definem-se: Wavelet “haar”, nível 3 e entropia “shannon”. [19, 36]

A entropia do tipo Shannon é uma entropia normalizada que envolve o logaritmo do valor quadrado de cada amostra de sinal:

$$-\sum s_i^2 \log(s_i^2) \quad (21)$$

A análise utilizada recorre à Wavelet Packet baseada em diferentes métodos de limiarização. Esta técnica exige a fixação de um valor de limiarização T dado por:

$$T = \sqrt{2 \log_e(n \log_2(n))} \quad (22)$$

onde n é o comprimento do sinal. [18]

Para parâmetros de limiarização seleciona-se o método “Fixed form”, limiarização “soft” e o limite de limiarização 60. [18, 35]

3.2.3. Reconhecimento de padrões

Após se retirar o ruído de todas as amostras recolhidas, extraem-se as características do sinal, classificando-o de seguida.. Para a extração e classificação do sinal foi utilizado o software Matlab para a implementação do método de extração de coeficientes da Wavelet Packet. Para a classificação dos sinais foram testados dois classificadores: Redes Neurais e Máquina de Vetores de Suporte. Cada um destes procedimentos vai ser discutido nas seções seguintes. [12, 13, 14, 20, 36, 37, 38]

3.2.3.1. Extração de Características

Recorrendo às funções da Wavelet Toolbox do software Matlab, é possível realizar a extração de características do sinal. Para parâmetros de extração deve ser escolhida a Wavelet Symmlet de ordem 4 com 5 níveis de decomposição pois assim haverá uma maior preservação

da informação do sinal EMG. Após ser criada a árvore de decomposição calcula-se o valor da energia de cada um dos nós terminais. Estes valores de energia serão utilizados como vetores de características para se proceder então à sua classificação. Dados os parâmetros de classificação, os vetores de características terão uma dimensão 1x32. [16, 17, 18, 24, 39]

3.2.3.2. Classificação

O processo de extração de características é importante para adquirir informação significativa para o processo de classificação. A função do processo de classificação é utilizar esta informação e gerar classes distintas correspondentes aos movimentos pretendidos: abrir e fechar a mão. [12]

O vetor de características do sinal vai ser aplicado aos seguintes classificadores: Redes Neurais e Máquina de Vetores de Suporte. [12]

3.2.3.2.1. Redes Neurais

Recorrendo às funções do Neural Net Pattern Recognition Toolbox do software Matlab pode realizar-se a classificação dos sinais recolhidos através de uma Rede Neuronal. [40]

Em primeiro lugar deve ajustar-se os vetores de características numa única variável de entrada. Como foram recolhidas 6 amostras para cada movimento, a variável de entrada deverá ter uma dimensão 12x32. Em seguida deve ser criada uma variável “target” que será uma matriz de dados onde os movimentos “abrir a mão” e “fechar a mão” são indicados pela primeira e segunda linha da matriz, respetivamente. A variável “target” terá duas linhas e o mesmo número de colunas que a variável de entrada, ou seja terá uma dimensão 2x32. [40]

É criada uma rede com 4 camadas ocultas. Este valor pode ser variável de modo a obter melhores resultados no classificador. [40]

Os dados deverão ser divididos em 80% para treino e os restantes 20% para teste. Os dados são divididos ao acaso. Procede-se ao treino do classificador e em seguida testa-se. [40, 41]

Corre-se o programa em Matlab. Poderá ser necessário correr o programa várias vezes até se obter uma boa resposta do classificador. O classificador calcula a matriz de outputs, a matriz de erros e o valor de performance. [40]

Para perceber melhor o funcionamento e a resposta dada pelo classificador é possível ainda visualizar a matriz de confusão e as curvas ROC. [40]

3.2.3.2.2. Máquina de Vetores de Suporte

Recorrendo às funções do Classification Learner Toolbox do software Matlab pode realizar-se a classificação dos sinais recolhidos através de uma Máquina de Vetores de Suporte. [42]

Em primeiro lugar deve juntar-se os vetores de características numa única variável de entrada “predictors”. Como foram recolhidas 6 amostras para cada movimento, a variável “predictors” deverá ter uma dimensão 12x32. Em seguida deve ser criada uma variável “resposta” de dimensão 12X1. Cada linha da variável de “resposta” corresponde à resposta de cada uma das linhas da variável “predictors”, ou seja, ‘Close’ ou ‘Open’. O classificador deve ser treinado em primeiro lugar com estas duas variáveis. [42]

Define-se um método de validação ‘Holdout’, dividindo os dados ao acaso 80% dos dados para treino e os restantes 20% para teste. Utilizam-se os dados de treino para criar o modelo de validação do classificador. A partir dos dados de teste calcula-se os erros de validação e a exatidão de validação. Utilizando este tipo de validação evita-se a sobreposição dos dados de treino e de teste obtendo-se uma melhor performance do classificador. [42, 43]

Calcula-se ainda as previsões de validação e os respetivos scores. O score indica a distância a que cada classe se encontra do hiperplano. [42]

4. Resultados

Com a obtenção dos sinais EMG apresentados no Anexo A (Gráficos dos sinais recolhidos durante a aquisição de dados para cada um dos movimentos), foi possível realizar o condicionamento dos sinais através do software Matlab, utilizando a Wavelet Toolbox.

No Anexo B (Código Matlab para o Condicionamento do Sinal e Gráficos dos sinais após o Condicionamento do Sinal) podemos ver os sinais após se lhes retirar o ruído.

Durante o processo de extração de características como se utilizou uma Wavelet do tipo Symmlet 4 com um nível de decomposição 5 obteve-se para cada um dos sinais um vetor de características de dimensão 1X32. O código para extração de características encontra-se no Anexo C (Código em Matlab para a Extração de Características).

Quando se aplica o classificador de Redes Neurais, este cria automaticamente a estrutura da rede, ver figura 4.1:

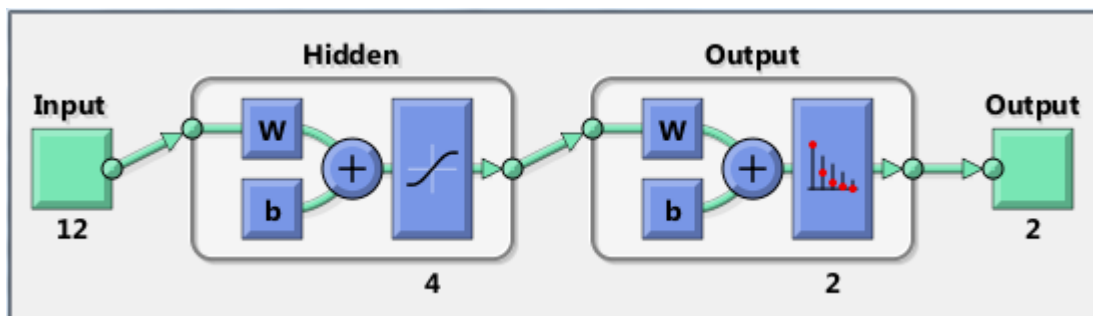


Figura 4.1 - Arquitetura da Rede Neuronal criada pelo classificador

O classificador de Redes Neurais apresenta os seus resultados na forma de uma matriz de outputs. O classificador cria uma matriz com uma dimensão 2X32, onde cada uma das linhas indica a saída de cada um dos movimentos. Para um resultado perfeito, esta matriz deveria ser uma matriz binária apenas com valores 0 ou 1, no entanto, apresenta algumas variações. Isto acontece porque o classificador não apresenta uma percentagem de erro de 0%.

De igual forma, o classificador cria também uma matriz de erros, de dimensão 2X32 onde cada linha indica o erro para cada movimento. Esta matriz é calculada subtraindo à matriz *targets* a matriz de outputs. Isto indica que para um funcionamento perfeito do classificador a matriz de outputs deveria ser igual à matriz *targets*.

Para este classificador obteve-se uma performance de 0.9359 (93,59%).

Após treinar o classificador é possível observar alguns gráficos relativos à performance do classificador. A figura 4.2 mostra a matriz de confusão para o treino, validação, teste e dos três tipos de dados combinados. Esta matriz mostra que as saídas da rede são relativamente precisas, dado o número mais elevado de respostas corretas representadas nos quadrados verdes, relativamente ao número mais baixo de respostas incorretas representadas nos quadrados vermelhos. A matriz de validação não apresenta resultados, dado ao facto de termos utilizado 0% de dados para validação. [40]



Figura 4.2 - Matriz de Confusão do classificador de Redes Neuronais

Na figura 4.3, encontram-se os gráficos das Curvas ROC (Receiver Operating Characteristic). As linhas coloridas em cada eixo representam as curvas ROC. As curvas ROC são gráficos de verdadeiros positivos (sensibilidade) versus falsos positivos (especificidade). Um teste

perfeito deve mostrar pontos no canto superior esquerdo, com 100% de sensibilidade e 100% de especificidade. Para este problema conseguimos obter valores perfeitos para os dados de treino, no entanto para os dados de teste os resultados ficam aquém do esperado. A curva de validação apresenta 0% de sensibilidade e 0% de especificidade dado ao facto de não termos utilizado dados de validação. [40]

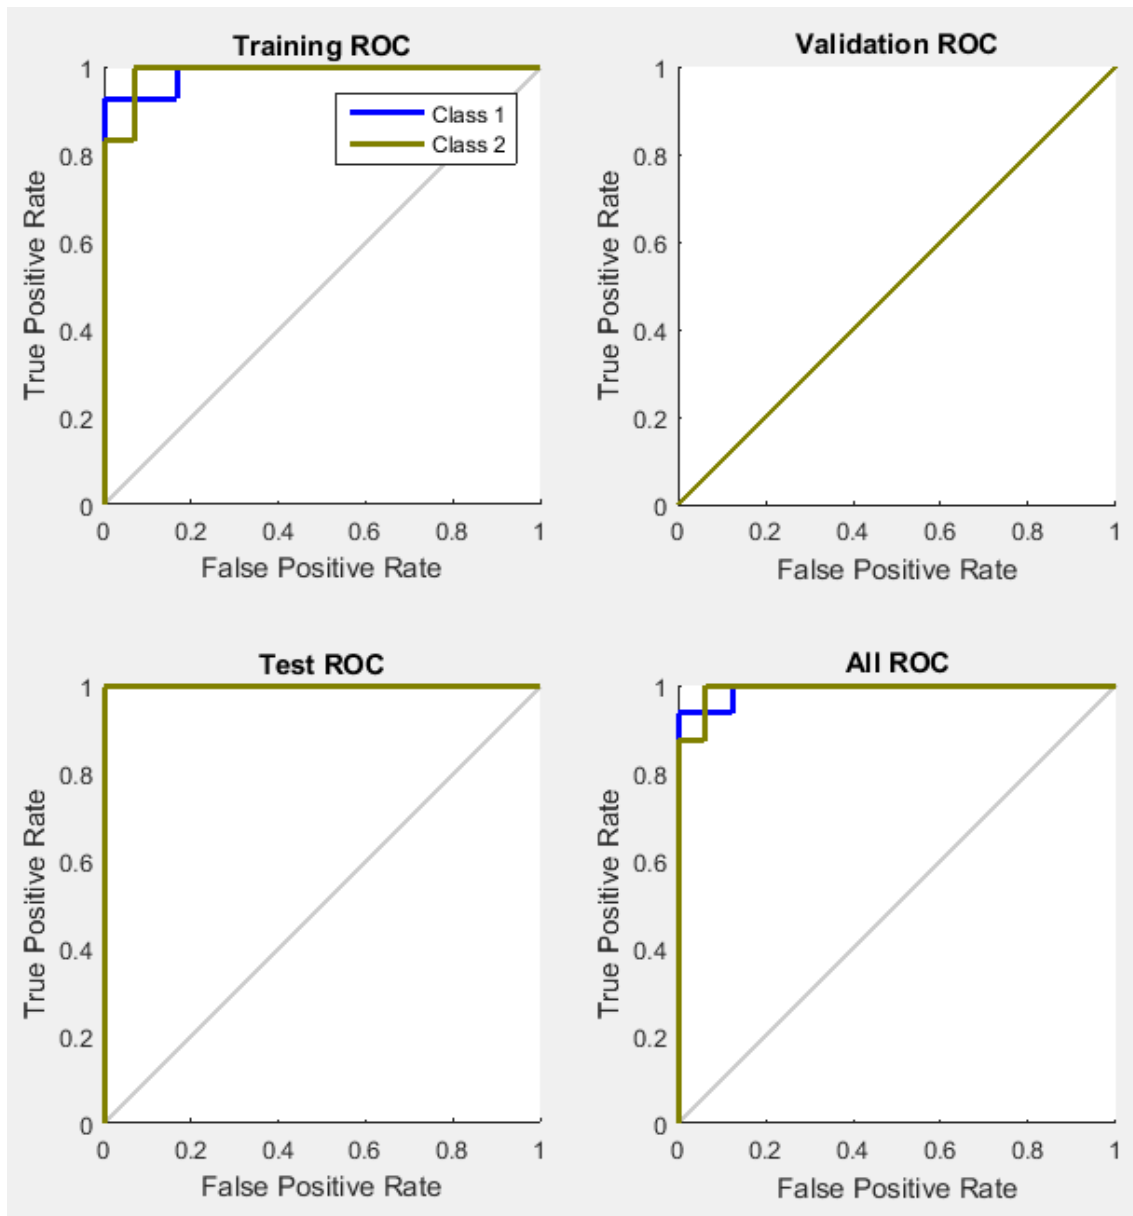


Figura 4.3 - Curvas ROC do classificador Redes Neurais

No Anexo D (Código Matlab para os Classificadores) encontra-se o código para a implementação do classificador de Redes Neurais.

Quando utilizamos um classificador de Máquinas de Vetores de Suporte, a resposta do classificador não é dada na forma de uma matriz de outputs. Aqui o classificador criou um

modelo de validação a partir dos dados de treino e as suas respectivas respostas. A partir deste modelo de validação o classificador consegue classificar novas amostras utilizando a função predict.

A figura 4.4 mostra o modelo de validação criado onde PredictorNames é uma matriz de strings que contém os nomes dos predictors pela ordem que aparecem em trainingPredictors, ResponseName é a string que descreve a variável de resposta trainingResponse, ClassNames é a lista dos elementos em trainingResponse sem repetições, ScoreTransform é a string que representa a função de transformação incorporada ou um identificador de função para transformar os scores de classificação previstos, NumObservations é o escalar que representa o número de observações nos dados de treino, Alpha é o vetor numérico dos coeficientes dos classificadores treinados a partir do duplo problema (isto é, os multiplicadores de Lagrange estimados), Bias é o escalar correspondente à duração da polarização do classificador treinado, KernelParameters é uma matriz estrutura que contém o nome do Kernel e os valores dos parâmetros, Mu é um vetor numérico com as médias dos predictors, Sigma é um vetor numérico com os desvios padrão dos predictors, BoxConstraints é um vetor numérico de restrições em caixa, ConvergenceInfo é uma matriz estrutura que contém as informações de convergência, IsSupportVector é um vetor lógico que indica se uma linha correspondente na matriz de dados predictors é um vetor de suporte e Solver é a string que indica a rotina de resolução que o software utiliza para treinar o classificador. [40]

```
>> svmtest
>> validationModel

validationModel =

ClassificationSVM
  PredictorNames: {1x32 cell}
  ResponseName: 'Y'
  ClassNames: {'Close' 'Open'}
  ScoreTransform: 'none'
  NumObservations: 10
  Alpha: [5x1 double]
  Bias: -0.7391
  KernelParameters: [1x1 struct]
  Mu: [1x32 double]
  Sigma: [1x32 double]
  BoxConstraints: [10x1 double]
  ConvergenceInfo: [1x1 struct]
  IsSupportVector: [10x1 logical]
  Solver: 'SMO'
```

Figura 4.4 - Modelo de Validação criado pelo classificador Maquinas de Vetores de Suporte

A função `predict` foi testada com os dados utilizados para teste (variável `validationPredictors`). A função cria duas matrizes: `validationPredictions` e `validationScores`. A matriz `validationPredictions` indica a classe de cada linha da matriz `validationPredictors`. A matriz `validationScores` contém as pontuações para classificar cada uma das observações/linhas da matriz `validationPredictors` indicando a distância a que cada observação está da fronteira de decisão. Como o problema aqui abordado apresenta duas classes, a matriz `validationScores` tem duas colunas e o mesmo número de linhas que a matriz `validationPredictors`, ou seja, tem uma dimensão 2×2 . Um score positivo para uma classe indica que `validationPredictors` é previsto estar nessa classe, um score negativo indica o contrário.

A figura 4.5 mostra o resultado obtido após se utilizar a função `predict`. As classes `Close` e `Open` encontram-se a uma distância da fronteira de decisão de ± 3.2001 e de ± 1.1005 , respetivamente, conforme o lado da fronteira que estamos a considerar.

```
>> validationPredictions

validationPredictions =

    'Close'
    'Open'

>> validationScores

validationScores =

    3.2001   -3.2001
   -1.1005    1.1005
```

Figura 4.5 - Resultados obtidos após a utilização da função `predict`

Para o classificador de Máquina de Vetores de Suporte obteve uma exatidão de validação de 100% e um erro de validação nulo.

No Anexo D (Código Matlab para os Classificadores) encontra-se o código para a implementação do classificador de Máquina de Vetores de Suporte.

5. Conclusão

Esta dissertação de mestrado teve como objetivo principal estudar o funcionamento das próteses mioelétricas e estudar e comparar os resultados de duas técnicas de classificação: Redes Neurais e Máquinas de Vetores de Suporte. Para isso pediu-se a ajuda a um voluntário do sexo feminino para se recolher alguns sinais mioelétricos de dois movimentos distintos: abrir e fechar a mão.

Os sinais mioelétricos foram registados através de um aparelho eletrónico (PowerLab74st) e foram depois analisados e trabalhados recorrendo ao software Matlab. Este software foi de extrema importância, uma vez que possuía toolboxes próprias que permitiam remover o ruído dos sinais e realizar a extração de características e classificação dos sinais.

Assim, após se realizar a classificação com as duas técnicas referidas, pude concluir que o classificador de Máquinas de Vetores de Suporte oferece uma melhor eficácia de classificação comparativamente ao classificador de Redes Neurais. No entanto, o desempenho de ambos os classificadores é fortemente influenciado pela divisão dos dados para treino, validação e teste. No classificador de Redes Neurais, o tamanho da rede influenciou também o desempenho do classificador, ou seja, um tamanho de rede maior ou menor do que 4 diminuía o valor de performance do classificador.

O melhor desempenho do classificador de Máquinas de Vetores de Suporte deverá dever-se ao facto de este classificador ser originalmente concebido para classificação binária. Isto é, o classificador foi inicialmente proposto para classificar dados em apenas duas classes.

Este trabalho poderia ter tido melhores resultados se fossem estudados mais métodos de extração de característica e de classificação.

Uma vez que a utilização de próteses mioelétricas ainda é rara, sugere-se que, em trabalhos futuros seja explorado o objetivo deste trabalho, recorrendo a equipamentos e meios que tornem o trabalho mais produtivo, assim como investigar o modo de processamento da informação ao nível dos sinais mioelétricos. Novas técnicas de extração devem ser propostas, bem como novos métodos de classificação, para no futuro conseguirmos obter melhores resultados de desempenho e performance neste tipo de próteses.

6. Bibliografia

1. Seeley R. Rod, Trend D. Stephens, P. T. (2003). Anatomia & Fisiologia. (M. - H. H. Education, Ed.) (6a ed.).
2. Richard L. Lieber. (2010). Skeletal Muscle Structure, Function, and Plasticity: The Physiological Basis of Rehabilitation. (L. W. & Wilkins, Ed.).
3. ADInstruments (Ed.). (1999). Physiology Experiments Manual - Windows, PowerLab/410. Australia.
4. J. Moore, G. Zouridakis, F. K. (2004). Biomedical Technology and Devices. (C. Press, Ed.). EUA: The mechanical engineering handbook series.
5. Frant, E., Milea, L., & But, V. (2012). Methods of Acquisition and Signal Processing for Myoelectric Control of Artificial Arms, 15(2), 91-105.
6. Kruger, L. M.; Fishman, S. (1993). Myoelectric and body-powered prostheses. J Pediatr Orthop, 13(1), 68-75.
7. Zecca, M., Micera, S., Carrozza, M. C., & Dario, P. (2002). Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal. Critical ReviewsTM In Biomedical Engineering, 30(4-6), 459-485.
- 8 Mandrup-Poulsen, T., & Jensen, J. S. (1982). Incidence of major amputations following gangrene of the lower limb. Prosthetics and Orthotics International, 6(1), 35-7.
9. Gaine, W. J.; Smart, C.; Bransby-Zachary, M. (1997). Upper Limb Traumatic Amputees. Journal of Hand Surgery, 22B(1), 73-76.
10. Rommers, G. M., Vos, L. D., Groothoff, J. W., Schuiling, C. H., & Eisma, W. H. (1997). Epidemiology of lower limb amputees in the north of The Netherlands: aetiology, discharge destination and prosthetic use. Prosthetics and Orthotics International, 21(2), 92-99.
11. Shinde, C. P. (2012). DESIGN OF MYOELECTRIC PROSTHETIC ARM, 1(1), 21-25.
12. G. Purushothaman, K. R. (2014). EMG based man-machine interaction - A pattern recognition research platform. Robotics and Autonomous Systems Journal, 62(6), 864 - 870.
13. K. Xing, P. Yang, J. Huang, Y. Wang, Q. Z. (2014). A real-time EMG pattern recognition method for virtual myoelectric hand control. Neurocomputing Journal, 136, 345 - 355.

14. Khokhar, Z. O., Xiao, Z. G., & Menon, C. (2010). Surface EMG pattern recognition for real-time control of a wrist exoskeleton. *Biomedical engineering online* (Vol. 9).
15. Karimi, M., Pourghassem, H., & Shahgholian, G. (2011). A novel prosthetic hand control approach based on genetic algorithm and wavelet transform features. *2011 IEEE 7th International Colloquium on Signal Processing and Its Applications, II*, 287-292.
16. Hu, X., Wang, Z., & Ren, X. (2005). Classification of surface EMG signal using relative wavelet packet energy. *Computer Methods and Programs in Biomedicine*, 79(3), 189-195.
17. Bach, P. F. (2009). Myoelectric signal features for upper limb prostheses.
18. MathWorks. (2015). *Wavelet Toolbox™ - User's Guide*.
19. Karlık, B. (2014). Machine Learning Algorithms for Characterization of EMG Signals. *International Journal of Information and Electronics Engineering*, 4(3).
20. Al-Faiz, M. Z., Ali, a. a., & Miry, a. H. (2010). A k-nearest neighbor based algorithm for human arm movements recognition using EMG signals. *Energy, Power and Control (EPC-IQ), 2010 1st International Conference on*, 6(2), 158-166.
21. Subasi, A., Yilmaz, M., & Ozcalik, H. R. (2006). Classification of EMG signals using wavelet neural network. *Journal of Neuroscience Methods*, 156(1-2), 360-367.
22. Singla, R. (2011). Comparison of SVM and ANN for classification of eye events in EEG. *Journal of Biomedical Science and Engineering*, 04(01), 62-69.
23. Chowdhury, R. H., Reaz, M. B. I., Ali, M. A. B. M., Bakar, A. a a, Chellappan, K., & Chang, T. G. (2013). Surface electromyography signal processing and classification techniques. *Sensors (Basel, Switzerland)*, 13(9), 12431-12466.
24. Subasi, A. (2012). Classification of EMG signals using combined features and soft computing techniques. *Applied Soft Computing*, 12(8), 2188-2198.
25. Oskoei, M. A. (n.d.). Evaluation of Support Vector Machines in Upper Limb Motion Classification Using Myoelectric Signal, 3-8.
26. Shenoy, P., Miller, K. J., Crawford, B., & Rao, R. P. N. (2008). Online Electromyographic Control of a Robotic Prosthesis, 55(3), 1128-1135.
27. Alkan, A., & Günay, M. (2012). Expert Systems with Applications Identification of EMG signals using discriminant analysis and SVM classifier. *Expert Systems With Applications*, 39(1), 44-47.


28. Fougner, A.; Stavadahl, O.; Kyberd, P.J.; Losier, Y.G.; Parker, P. A. (2012). Control of Upper Limb Prostheses: Terminology and Proportional Myoelectric Control - A Review. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 20(5), 663 - 677.
29. Fougner, A. (2013). Robust, Coordinated and Proportional Myoelectric Control of Upper-Limb Prostheses.
30. Pelletier, J. (2013). Touch Bionics i-Limb Prostheses.
31. J. Belter, J. Segil, A. Dollar, W. R. (2013). Mechanical design and performance specifications of anthropomorphic prosthetic hands: A review. The Journal of Rehabilitation Research and Development, 50(5), 599.
- 32 ADInstruments. (2000). Chart v4.0 Extension's User's Guide - for Windows, PowerLab/4st, 29 - 30.
33. P. Shenoy, K. Miller, B. C. et al. (2008). Online Electromyographic Control of a Robotic Prosthesis. IEEE Transactions on Biomedical Engineering, 55(3), 1128 - 1135.
34. Al-faiz, M. Z., & Miry, A. H. (2012). Artificial Human Arm Driven by EMG Signal.
35. Bhoi, A. K., Tamang, J. S., & Mishra, P. (2012). Wavelet packet based Denoising of EMG Signal, 4(2), 78-83.
36. S. Herle, S. Man, G. Lazea, P. R. (2012). Myoelectric Control Strategies for a Human Upper Limb Prosthesis. CEAL, 14(1), 58-66.
37. K. Veer. (2015). A technique for classification and decomposition of muscle signal for control of myoelectric prostheses based on wavelet statistical classifier. Measurement Journal, 60, 283 - 291.
38. Khezri, M., & Jahed, M. (2007). Real-time intelligent pattern recognition algorithm for surface EMG signals. Biomedical Engineering Online, 6, 45.
39. Subasi, A. (2012). Classification of EMG signals using combined features and soft computing techniques. Applied Soft Computing, 12(8), 2188-2198.
40. MathWorks. (2015). Neural Net Pattern Recognition Toolbox™ - User's Guide.
41. Karthikeyan, P., Murugappan, M., & Yaacob, S. (2012). EMG Signal Based Human Stress Level Classification Using Wavelet Packet Transform. Trends in Intelligent Robotics, 236-243.
42. MathWorks. (2015). Statistics and Machine Learning Toolbox™ - User's Guide.

43. El-habi, A. M., Statistics, A., & El-ghareeb, M. (2015). Evaluation of Data Mining Classification Models Evaluation of Data Mining Classification.


**ANEXO A - Gráficos dos sinais recolhidos durante a
aquisição de dados para cada um dos
movimentos**

Movimento: Fechar Mão


Frame 1




Frame 2




Frame 3




Frame 4



Frame 5




Frame 6




Movimento: Abrir Mão


Frame 1




Frame 2




Frame 3




Frame 4



Frame 5



Frame 6



**ANEXO B - Código Matlab para o condicionamento
do sinal e gráficos dos sinais após o
condicionamento do sinal**

Código Matlab para condicionamento de sinal

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%
% DENOISING SIGNALS
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%

% Parâmetros de Análise
%-----
Wav_Nam = 'haar';
Lev_Anal = 3;
Ent_Nam = 'shannon';
Ent_Par = 0;

% Parâmetros Denoising
%-----
% meth = 'sqtwologuwn';
sorgh = 's'; % Especifica 'soft' ou 'hard' thresholding
thrSettings = {sorgh, 'nobest', 60.00000000000000, 1};

% Decomposição usando WPDEC.
%-----
wpt1 = wpdec(frame1, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt2 = wpdec(frame2, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt3 = wpdec(frame3, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt4 = wpdec(frame4, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt5 = wpdec(frame5, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt6 = wpdec(frame6, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt7 = wpdec(frame7, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt8 = wpdec(frame8, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt9 = wpdec(frame9, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt10 = wpdec(frame10, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt11 = wpdec(frame11, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);
wpt12 = wpdec(frame12, Lev_Anal, Wav_Nam, Ent_Nam, Ent_Par);

% Nós para onde imerge
%-----
n2m = [];
for j = 1:length(n2m)
    wpt1 = wpjoin(wpt1, n2m(j));
    wpt2 = wpjoin(wpt2, n2m(j));
    wpt3 = wpjoin(wpt3, n2m(j));
    wpt4 = wpjoin(wpt4, n2m(j));
    wpt5 = wpjoin(wpt5, n2m(j));
    wpt6 = wpjoin(wpt6, n2m(j));
    wpt7 = wpjoin(wpt7, n2m(j));
    wpt8 = wpjoin(wpt8, n2m(j));
    wpt9 = wpjoin(wpt9, n2m(j));
    wpt10 = wpjoin(wpt10, n2m(j));
    wpt11 = wpjoin(wpt11, n2m(j));
    wpt12 = wpjoin(wpt12, n2m(j));
end


% Denoise usando WPDENCMP.
%-----
[sigDEN1, wptDEN1] = wpdencmp(wpt1, thrSettings{:});
[sigDEN2, wptDEN2] = wpdencmp(wpt2, thrSettings{:});
[sigDEN3, wptDEN3] = wpdencmp(wpt3, thrSettings{:});
```

```
[sigDEN4,wptDEN4] = wpdencmp(wpt4,thrSettings{:});  
[sigDEN5,wptDEN5] = wpdencmp(wpt5,thrSettings{:});  
[sigDEN6,wptDEN6] = wpdencmp(wpt6,thrSettings{:});  
[sigDEN7,wptDEN7] = wpdencmp(wpt7,thrSettings{:});  
[sigDEN8,wptDEN8] = wpdencmp(wpt8,thrSettings{:});  
[sigDEN9,wptDEN9] = wpdencmp(wpt9,thrSettings{:});  
[sigDEN10,wptDEN10] = wpdencmp(wpt10,thrSettings{:});  
[sigDEN11,wptDEN11] = wpdencmp(wpt11,thrSettings{:});  
[sigDEN12,wptDEN12] = wpdencmp(wpt12,thrSettings{:});
```


Gráficos dos sinais após condicionamento do sinal

Movimento: Fechar Mão


Frame 1




Frame 2




Frame 3




Frame 4



Frame 5




Frame 6




Movimento: Abrir Mão


Frame 1




Frame 2




Frame 3




Frame 4



Frame 5



Frame 6



ANEXO C - Código em Matlab para a extração de características

Código Matlab para extração de características

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%
% EXTRAÇÃO DE CARACTERÍSTICAS
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%
% Vetores de características extraídos da Wavelet Packet 1-D Toolbox
% Ordem (2-Sinais, 4-Imagens),
% Árvore de nível 5
% Wavelet: Symmlet 4

wpt1=wptree(2,5,sigDEN1,'sym4','shannon',0);
wpt2=wptree(2,5,sigDEN2,'sym4','shannon',0);
wpt3=wptree(2,5,sigDEN3,'sym4','shannon',0);
wpt4=wptree(2,5,sigDEN4,'sym4','shannon',0);
wpt5=wptree(2,5,sigDEN5,'sym4','shannon',0);
wpt6=wptree(2,5,sigDEN6,'sym4','shannon',0);
wpt7=wptree(2,5,sigDEN7,'sym4','shannon',0);
wpt8=wptree(2,5,sigDEN8,'sym4','shannon',0);
wpt9=wptree(2,5,sigDEN9,'sym4','shannon',0);
wpt10=wptree(2,5,sigDEN10,'sym4','shannon',0);
wpt11=wptree(2,5,sigDEN11,'sym4','shannon',0);
wpt12=wptree(2,5,sigDEN12,'sym4','shannon',0);

% Extração dos coeficientes de último nível com os valores da sua
energia

energy1=wenergy(wpt1);
energy2=wenergy(wpt2);
energy3=wenergy(wpt3);
energy4=wenergy(wpt4);
energy5=wenergy(wpt5);
energy6=wenergy(wpt6);
energy7=wenergy(wpt7);
energy8=wenergy(wpt8);
energy9=wenergy(wpt9);
energy10=wenergy(wpt10);
energy11=wenergy(wpt11);
energy12=wenergy(wpt12);
```

ANEXO D - Código em Matlab para os classificadores

Redes Neurais

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%
% CLASSIFICAÇÃO: REDES NEURONAIS
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%

% Criação das variáveis para o Classificador de Redes Neurais

% A variável inputs é composta pelas características extraídas dos
% diferentes frames.
% Foram extraídas 32 características para cada frame
% Então a variável inputs será uma matriz 12x32

inputs=[energy1; energy2; energy3; energy4; energy5; energy6; energy7;
energy8; energy9; energy10; energy11; energy12];

% Criação de uma variável target:
% A variável targets é uma matriz de dados onde os movimentos abrir e
% fechar são indicados pela primeira e segunda linhas da matriz,
% respetivamente.

targets=size(2,32); % Alocação de memória para a variável targets

for i=1:2
    for j=1:32
        if i==1
            if mod(j,2)== 1
                targets(i,j)=1;
            else
                targets(i,j)=0;
            end
        else
            if mod(j,2)== 1
                targets(i,j)=0;
            else
                targets(i,j)=1;
            end
        end
    end
end

% % Criação de um Classificador
hiddenLayerSize = 4;
net = patternnet(hiddenLayerSize);

% % Divisão dos dados para Treino, Validação e Teste
net.divideParam.trainRatio = 80/100;
net.divideParam.valRatio = 0/100;
net.divideParam.testRatio = 20/100;

% % Treino do Classificador
[net,tr] = train(net,inputs,targets);

% % Teste do Classificador
outputs = net(inputs);
errors = gsubtract(targets,outputs);
```

```
entropy = crossentropy(net,targets,outputs); % Performance baseada na
% cross-entropy. Valores baixo de cross-entropy resultam normalmente
% numa boa classificação. Quanto mais baixo for o valor melhor.
performance=1-entropy;

% % View the Network
view(net)
```

Máquina de Vetores de Suporte

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% CLASSIFICAÇÃO: MÁQUINA DE VETORES DE SUPORTE
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Criação das variáveis de entrada para o classificador
predictors=[energy1; energy2; energy3; energy4; energy5; energy6;
energy7; energy8; energy9; energy10; energy11; energy12];
response={'Close'; 'Close'; 'Close'; 'Close'; 'Close'; 'Close';
'Open'; 'Open'; 'Open'; 'Open'; 'Open'; 'Open'};

%Treino do Classificador
trainedClassifier=fitcsvm(predictors, response, 'Standardize', true);

% Seleciona uma percentagem de dados para serem utilizados como
% conjunto de test. O modelo é treinado no conjunto de treino e a
% performance é avaliada com o conjunto de teste.

cvp = cvpartition(response, 'Holdout', 0.2); % 20 por cento dos dados
% utilizados como conjunto de teste

trainingPredictors = predictors(cvp.training, :); %Dados de treino

trainingResponse = response(cvp.training, :); %Respostas
% correspondentes aos dados de treino

% Treino do Classificador
validationModel = fitcsvm(trainingPredictors,
trainingResponse, 'Standardize', true);

% Cálculo da exatidão da validação
validationPredictors = predictors(cvp.test, :);
validationResponse = response(cvp.test, :);
validationError=loss(validationModel, validationPredictors,
validationResponse, 'LossFun', 'ClassifError'); %Percentagem = 0%
validationAccuracy = 1 - validationError; % Percentagem=100%

% Cálculo das previsões de validação e os respetivos Scores
[validationPredictions, validationScores] = predict(validationModel,
validationPredictors);
```