

• U • C •

FCTUC FACULDADE DE CIÊNCIAS
E TECNOLOGIA
UNIVERSIDADE DE COIMBRA

DEPARTAMENTO DE
ENGENHARIA MECÂNICA

Estimativa de ângulos de junta de dedos a partir de sinais EMG

Dissertação apresentada para a obtenção do grau de Mestre em Engenharia Mecânica na Especialidade de Produção e Projecto

Estimating fingers joint angles from muscle signals

Autor

José Pedro Alves Allen Lima

Orientadores

Professor Doutor Miguel Simão

Professor Doutor Pedro Mariano Neto

Júri

Presidente Professor Doutor **Cristóvão Silva**
Professor Auxiliar da Universidade de Coimbra

Vogais Professor Doutor **Nuno Alberto Marques Mendes**
Professor Auxiliar da Universidade de Coimbra

Orientador Professor Doutor **Pedro Mariano Neto**
Professor da Universidade de Coimbra

Coimbra, Setembro, 2016

“In the middle of difficulty lies opportunity.”

Albert Einstein

Aos meus pais, tia e avós

Agradecimentos

A realização desta dissertação não seria possível sem o contributo e apoio de algumas pessoas, às quais não posso deixar de prestar o meu mais profundo reconhecimento e sincero agradecimento.

Ao orientador, Professor Doutor Pedro Mariano Simões Neto, pela oportunidade de trabalhar com ele numa área que sempre me fascinou e me despertou curiosidade. Obrigada pela sua ajuda e atenção dadas em momentos mais complicados.

Ao professor Nuno Alberto Marques Mendes, por toda a sua calma e ajuda no desenvolvimento da parte prática deste trabalho.

Aos colegas e amigos bairradinos, por tudo o que passámos juntos, ao longo de todos estes anos, e por serem a minha segunda família.

À minha família, em particular às pessoas que sempre foram o centro da minha vida, os meus pais, a tia/madrinha e avós. Aos pais, por todo o esforço e dedicação gastos comigo, ao longo da minha vida, e por tudo o que fizeram questão de sempre me proporcionarem, à minha tia e madrinha, que sempre foi como uma mãe para mim, aos meus avós que me criaram, quando era mais novo, e sempre me ajudaram e acarinharam incondicionalmente, com especial destaque para o meu avô que foi a razão específica de ter optado por este tema, uma vez que poderia ter sido aplicado nele, melhorando assim os seus dias. Sem estas pessoas este percurso teria sido impossível!

Obrigado por tudo.

Resumo

O uso de sinais musculares é cada vez mais utilizado para controlar dispositivos robóticos nos dias de hoje. Os sinais mais utilizados são os sinais EMG, uma vez que permitem um acesso fácil e não invasivo a sinais biológicos dos seres humanos. Contudo, este tipo de sinais, tem a grande desvantagem de não ser constante e variar de pessoa para pessoa, e mesmo em cada pessoa pode variar consoante vários factores. Deste modo, para este tipo de sinais musculares poder ser usado na identificação da posição das articulações, é necessário tratar estes sinais, de modo a que se consiga retirar deles informação útil para a identificação da posição das articulações. Este trabalho baseia-se no uso dessa informação para a identificação do tipo de movimento feito pela mão de um utilizador. Uma técnica que tem vindo a revelar-se bastante eficiente é o uso de uma rede neuronal com *Pattern Recognition*, contudo para o uso desta técnica é necessário um conjunto muito específico de sub-rotinas relativamente complexas.

Nesse sentido, o objectivo principal deste trabalho é desenvolver um *software* que permita a identificação *off-line*, de movimentos feitos pela mão de um utilizador. Após haver uma captação dos sinais EMG de um utilizador, enquanto este realiza determinados gestos, ir-se-á dividir os sinais EMG correspondentes a cada tipo de movimento presente nos gestos feitos. Em seguida, o *software*: cria uma matriz alvo, correspondente aos movimentos presentes no gesto; filtra os sinais EMG; faz o cálculo de uma *feature* proveniente dos sinais já filtrados; gera uma rede neuronal com *Pattern Recognition*; faz o treino necessário para que a rede neuronal consiga associar os sinais EMG do utilizador ao movimento que estava a ser feito.

Após estas etapas, o *software* será capaz de identificar o tipo de movimento presente em determinado *frame* do gesto.

Por fim, este *software* é usado para identificar a posição inicial, o início do movimento e o fim do movimento, em cinco gestos diferentes, usando os sinais que foram utilizados para o treino da rede e usando sinais que não foram usados no treino, de forma a comparar a eficiência do reconhecimento entre os dois tipos de sinais.

Palavras-chave: sinais EMG, *Pattern Recognition*, reconhecimento, *off-line*, matriz alvo, *feature*.

Abstract

Nowadays, the use of muscle signs is increasingly employed to control robotic devices. The EMG signs are the most used, once they allow an easy and not invasive access to biological signals of the human beings. Nevertheless, this kind of signals has the great advantage of not being constant and varying from person to person; it can even vary in each person depending of different factors. Thus, so this kind of muscle signs can be used when identifying the positions of the joints, it is necessary to take care of the signs in order to get useful information from them to identify the sort of movement done by a hand's user. The use of a neural network with *Pattern Recognition* is a technique that has been revealing itself highly effective. However, to the use this technique, it is necessary a very specific range of relatively complex subroutines.

Accordingly, the main aim of this work is to develop software that allows the off-line identification of movements done by a user's hand. After capturing a user's EMG signals, while performing some actions, the EMG signals will be divided corresponding to each kind of movement presented in the gesture made; next, the software creates a target matrix corresponding to the movements presented in the gesture. Following, it filters the EMG signs and makes the calculations of a feature from already filtered signs. It generates a neuronal network with *Pattern Recognition*. It does the necessary training so that the neuronal network is able to associate the user's EMG signals to the movement that was being done.

After these steps, the software will be able to identify the kind of movement used in a specific frame of the gesture.

Finally, this software is used to identify the initial position, the beginning and the end of the movement in five different gestures, using the signs that have been used to the network training and using signs that haven't been used in the training in order to compare the recognition efficiency between the two kinds of signs.

Keywords EMG signs, Pattern Recognition, identify, off-line, target matrix, feature.

Índice

Índice de Figuras	xii
Índice de Tabelas	xiv
Simbologia e Siglas	xvi
Simbologia.....	xvi
Siglas	xvii
1. INTRODUÇÃO.....	1
1.1. Enquadramento	1
1.2. Objectivos	2
1.3. Estrutura da dissertação	3
2. Revisão Bibliográfica	4
2.1. EMG.....	4
2.1.1. Vantagens e desvantagens dos sinais EMG.....	8
2.2. Dispositivos controláveis a partir de sinais EMG.....	9
2.2.1. Artigos científicos	9
2.3. <i>Features</i>	13
2.4. Filtros digitais	18
2.4.1. Vantagens e desvantagens	19
2.4.2. Terminologia	19
2.4.3. Tipos de filtro digital	20
3. Definição do problema	23
3.1. Equipamento de captação de sinais EMG.....	23
3.1.1. Equipamento e Características do <i>Myo Gesture Control</i>	23
3.1.2. Preparação do <i>Myo Gesture Control</i>	24
3.2. Filtro digital	25
3.3. Matriz alvo	28
3.4. <i>Feature</i> e <i>Sliding Window</i>	31
3.5. Rede Neuronal	33
4. Procedimento e resultados obtidos	34
4.1. Captação dos sinais EMG	36
4.2. Pré-Processamento.....	39
4.2.1. Tipos de movimentos	39
4.2.2. Aplicação de um <i>low-pass filter</i>	41
4.3. Rede Neuronal	43
5. Conclusões e trabalhos futuros	53
REFERÊNCIAS BIBLIOGRÁFICAS	55
ANEXO A	57

ÍNDICE DE FIGURAS

Figura 2.1. Evolução do uso de sinais EMG em próteses(Federico Carpi e Danilo de Rossi).	4
Figura 2.2. Esboço da captação e decomposição dos sinais EMG (Carlo J. De Luca, et.al, 2006).	5
Figura 2.3. Esquema para a aquisição e análise de um sinal EMG (Federico Carpi e Danilo de Rossi).....	6
Figura 2.4. Diagrama de bloco de processamento de sinal EMG para detecção do nível de activação muscular (Federico Carpi e Danilo de Rossi).	7
Figura 2.5. Bandas de filtro (S.S. Young,2001).	20
Figura 2.6. Efeito de um <i>High pass filter</i> e de um <i>Low pass filter</i> num sinal (NDT Resource Center).....	21
Figura 3.1. Pulseira <i>Myo Gesture Control</i>	23
Figura 3.2. Conjunto <i>Myo Gesture Control</i>	24
Figura 3.3. Gestos a realizar para a calibração do <i>Myo Gesture Control</i>	25
Figura 3.4. Código do <i>Low Pass Filter</i> em MATLAB	26
Figura 3.5.Sinal filtrado com uma ordem de 6 e com a frequência de corte a variar; a) Resultados do <i>Low Pass Filter</i> com uma frequência de corte de 2 Hz; b) Resultados do <i>Low Pass Filter</i> com uma frequência de corte de 3 Hz; c) Resultados do <i>Low Pass Filter</i> com uma frequência de corte de 6 Hz.....	26
Figura 3.6. Sinal filtrado com ua frequência de corte de 2 Hz e com a ordem do filtro a variar; a) Resultados do <i>Low Pass Filter</i> com uma ordem de filtro 2; b) Resultados do <i>Low Pass Filter</i> com uma ordem de filtro 4; c) Resultados do <i>Low Pass Filter</i> com uma ordem de filtro 6	27
Figura 3.7. Vetores para cada movimento e respectivo valor	29
Figura 3.8.Informação do tipo de gesto presente a cada <i>frame</i> : a) dados dos sinais EMG e respetivo valor do primeiro movimento; b) dados dos sinais EMG e respetivo valor do segundo movimento; c) dados dos sinais EMG e respetivo valor do terceiro movimento	30
Figura 3.9. Código MATLAB para a criação da matriz alvo.....	31
Figura 3.10. Código em MATLAB para o calculo da <i>feature</i>	32
Figura 3.11. Representação da rede neuronal utilizada.....	33
Figura 4.1. Algoritmo do sistema.....	34
Figura 4.2.Movimentos presentes no gesto punho: a) posição inicial; b) início do movimento; c) fim do movimento	37

Figura 4.3. Sinais EMG do movimento dedos1 captados pelo elétrodo1.	38
Figura 4.4.Divisão de movimentos para os vários gestos: a) dedos; b) flexão palmar; c) indicador; d) punho; e) pronação.....	40
Figura 4.5. Comparação do sinal original com o mesmo sinal filtrado no movimento dedos: a) comparação para os sinais provenientes do elétrodo nº1; b) comparação para os sinais provenientes do elétrodo nº2; c) comparação para os sinais provenientes do elétrodo nº3; d) comparação para os sinais provenientes do elétrodo nº4; e) comparação para os sinais provenientes do elétrodo nº5; f) comparação para os sinais provenientes do elétrodo nº6; g) comparação para os sinais provenientes do elétrodo nº7; h) comparação para os sinais provenientes do elétrodo nº8.....	42

ÍNDICE DE TABELAS

Tabela 2.1. Fórmulas de <i>features</i>	16
Tabela 2.2. Fórmulas de <i>features</i>	18
Tabela 4.1. Exemplo de sinais EMG do movimento dedos1	37
Tabela 4.2. Exemplo de sinais EMG do movimento dedos1	39
Tabela 4.3. Reconhecimento dos movimentos no gesto dedos usando os dados que foram utilizados para o treino da rede neuronal	44
Tabela 4.4. Reconhecimento dos movimentos no gesto dedos2	44
Tabela 4.5. Reconhecimento dos movimentos no gesto dedos3	45
Tabela 4.6. Reconhecimento dos movimentos no gesto indicador usando os dados de treino	46
Tabela 4.7. Reconhecimento dos movimentos no gesto indicador2	46
Tabela 4.8. Reconhecimento dos movimentos no gesto indicador3	47
Tabela 4.9. Reconhecimento dos movimentos no gesto pronação do pulso usando os dados de treino.....	48
Tabela 4.10. Reconhecimento dos movimentos no gesto pronação do pulso 2	48
Tabela 4.11. Reconhecimento dos movimentos no gesto pronação do pulso 3	49
Tabela 4.12. Reconhecimento dos movimentos no gesto flexão palmar com dados de treino	49
Tabela 4.13. Reconhecimento dos movimentos no gesto flexão palmar2	50
Tabela 4.14. Reconhecimento dos movimentos no gesto flexão palmar3	50
Tabela 4.15. Reconhecimento dos movimentos no gesto punho com dados de treino	51
Tabela 4.16. Reconhecimento dos movimentos no gesto punho2	51
Tabela 4.17. Reconhecimento dos movimentos no gesto punho3	52

SIMBOLOGIA E SIGLAS

Simbologia

$sEMG(n)$ – Número da amostra discreta do sinal EMG

$sEMG_{rec}(n)$ – Tempo de serie do sinal EMG depois da rectificação full-wave

N – Número de subamostras

$sEMG_{ss}(n)$ – Tempo de serie do sinal EMG depois da subamostragem

p – Vector de dados de entrada na rede neuronal.

b_{in} – Valor do vector limite para a camada intermédia

b_{out} – Valor do vector limite para a camada de saída

W_{in} – Peso da matriz da camada intermédia

W_{out} – Peso da matriz da camada de saída

$\tilde{\theta} = [\tilde{\theta}_{tornozelo}, \tilde{\theta}_{joelho}, \tilde{\theta}_{anca}]$ – Estimativa dos ângulos das três articulações

$\tilde{\theta}_i$ – Estimativa do ângulo da articulação no tempo i

m – Ordem do modelo

a – Valor do sinal EMG num músculo

f – Função não linear

k – Número de canais dos sinais EMG

l – Número total de neurónios de dados de entrada

$s(n)$ – Série de tempo do sinal EMG

P – Ordem do modelo AR

a_i – Coeficiente AR

$e(n)$ – *Gaussian white noise*

n – Número de amostras da *sliding window*

x_k – Amostra k do sinal x

ms – Micro segundo

μV – microvolts

mV – milivolts

Siglas

EMG – electromiograma

DEM – Departamento de Engenharia Mecânica

FCTUC – Faculdade de Ciências e Tecnologia da Universidade de Coimbra

MIT – Massachusetts Institute of Technology

AVC– Acidente Vascular Cerebral

1. INTRODUÇÃO

1.1. Enquadramento

O surgimento de robôs deu-se há cerca de cinquenta anos e com eles a vida do Homem mudou. Com efeito, através da sua utilização, em diversas áreas, fomos capazes de melhorar processos repetitivos, bem como tarefas que exigiam uma precisão bastante apurada. Graças a eles, tornámos as nossas linhas de produção mais eficientes e mais rápidas, conseguimos salvar mais vidas e conseguimos trabalhar e explorar ambientes nunca antes explorados devido às suas condições extremas e inapropriadas para o ser humano.

Porém, passados cinquenta anos, estamos inseridos num mundo completamente diferente. Vivemos num tempo em que cada vez mais se quer realizar bem todas as actividades, de forma simples e eficaz e, principalmente, nos dias que correm, quer executar-se tudo à distância, sem necessitar de recorrer a grandes dispositivos, de modo a que se possa mandar fazer tarefas enfadonhas, sem ter que estar perto do robô, pois o homem, ao longo da sua história, sempre primou pela comodidade. Como tal, os robôs são cada vez mais usuais no dia-a-dia do Homem. Daí a crescente importância de saber como usar e controlar um robô. Assim, com a banalização deste tipo de dispositivo, a interface humano-robô tem que ser cada vez mais simples e intuitiva, de modo a que seja fácil para qualquer pessoa poder manusear um robô.

E que maneira mais simples de controlar um robô, do que ele conseguir interpretar sinais físicos do utilizador e executar o que este quer, sem ter que carregar em qualquer botão ou lidar com qualquer programa?

Da resposta a esta questão surge o tema desta tese que se foca na estimativa dos ângulos da articulação, através de sinais musculares provenientes do utilizador, captados através de eléctrodos, que irão captar os sinais eletromiográficos, mais vulgarmente designados por EMG . Com efeito, se conseguirmos que o robô reconheça e replique os movimentos da mão do utilizador, através dos sinais musculares do mesmo, abre-se uma vasta gama de possibilidades de utilizações para a manipulação de robôs, tais

como manusear objectos perigosos ou em ambientes perigosos a uma distância que não ponha o utilizador em risco, com a mesma destreza e subtileza da mão humana, poder controlar os movimentos de uma linha de produção robótica, apenas mexendo o seu braço, sem ter de usar uma luva robótica.

Além disso, por exemplo, as pessoas amputadas poderiam novamente movimentar uma prótese da mesma forma e praticamente de forma instantânea, como faziam anteriormente com o seu membro completo.

A concluir, ajudaria também na reabilitação e na recuperação de pessoas, que, por algum motivo, tivessem perdido a capacidade de mexer a sua mão como desejavam.

Porém esta tecnologia ainda levanta alguns problemas na sua concepção, dos quais o maior é a captação e leitura dos sinais musculares, sinais EMG, provenientes do utilizador, o que faz com que a mão robótica não execute determinados movimentos ou demore algum tempo até replicar o movimento feito pelo utilizador, uma vez que os sinais têm uma intensidade baixa. Dentro deste problema surgem ainda mais complicações, tais como a deslocação dos eléctrodos da sua posição inicial, durante os movimentos do utilizador, conseguir que o programa seja capaz de interpretar os sinais EMG correspondentes ao movimento dos dedos e os programas existentes não terem em consideração a fadiga muscular, nem se o utilizador esteja doente, aquando da leitura dos sinais EMG.

Outro problema que surge é que os sinais EMG são inerentes a cada ser humano, ou seja, variam de pessoa para pessoa, por isso não existe um algoritmo que consiga interpretar os sinais de todas as pessoas que queiram utilizar este tipo de método.

1.2. Objectivos

Neste trabalho o objectivo principal é criar um *software* que consiga reconhecer gestos da mão do utilizador através dos seus sinais EMG. Para tal, irão ser desenvolvidas várias acções de modo a que se consiga a melhor eficiência de reconhecimento possível e se tente resolver e lidar com os problemas que foram referidos anteriormente.

É pretendido, mais concretamente, que:

- O *software* seja totalmente automático, cabendo apenas ao utilizador colocar o dispositivo de captação de sinais EMG e fazer a divisão dos dados correspondentes a cada movimento;
- O procedimento seja flexível, de modo que após o treino, este consiga reconhecer qualquer tipo de gesto pretendido pelo utilizador;
- O *software* tenha a capacidade de dentro de cada tipo de gesto conseguir reconhecer a posição inicial, o início do movimento e o fim do respectivo movimento;
- O *software* consiga reconhecer todos os sinais EMG, mesmo aqueles que não foram usados para treinar o *software*.

1.3. Estrutura da dissertação

A presente dissertação está dividida em cinco capítulos:

- Capítulo 2: Este capítulo tem o intuito de descrever conceitos e definições teóricas importantes para uma boa compreensão do presente trabalho. São ainda abordados estudos feitos por outros autores que abordam temas que se inserem nesta dissertação, bem como exemplos de abordagens para se estimar os ângulos das articulações;
- Capítulo 3: Neste capítulo é definido o problema. É ainda feito uma descrição de como este trabalho foi realizado;
- Capítulo 4: Diz respeito à análise, comparação e discussão dos resultados obtidos;
- Capítulo 5: Capítulo onde irão ser apresentadas as conclusões finais da dissertação e são propostos trabalhos futuros.

2. REVISÃO BIBLIOGRÁFICA

2.1. EMG

É um sinal eléctrico gerado pela actividade neuromuscular que pode ser detectado através de métodos invasivos ou não invasivos. Como método invasivo pode ser obtido, através de agulhas colocadas diretamente no tecido muscular, como método não invasivo poderá obter-se colando-se elétrodos na superfície da pele. Estes sinais fornecem um acesso fácil aos processos fisiológicos responsáveis pela contracção muscular no ser humano.

Nos últimos trinta anos os sinais EMG, a sua captação e análise computacional têm sido alvo de estudo na área da engenharia, principalmente na vertente biomédica, devido às suas possíveis aplicações no controlo de próteses e exosqueletos.

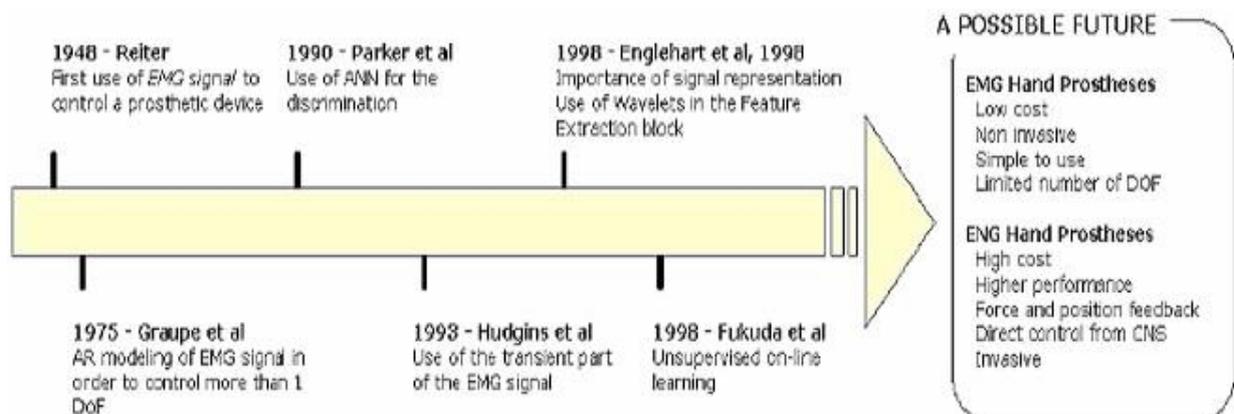


Figura 2.1. Evolução do uso de sinais EMG em próteses(Federico Carpi e Danilo de Rossi).

Como se demonstra na figura 2.1, Reiter foi o primeiro a usar os sinais EMG para controlar os movimentos de uma prótese simples. Contudo, nos últimos anos têm-se assistido a um maior esforço em tentar implementar algoritmos que consigam ter

um controlo mais efectivo dos movimentos baseados no processamento de sinais EMG de para que se consiga melhorar a funcionalidade e a usabilidade de dispositivos (Federico Carpi, Danilo de Rossi).

Na perspectiva de Federico Carpi e Danilo de Rossi os valores obtidos através do EMG variam devido à complexidade das operações na captação e leitura desses sinais, assim sendo é necessário calibrar o sistema ao utilizador ou treinar o utilizador a usar o sistema de modo a que se consiga criar um padrão dos sinais EMG para cada tipo de movimento do utilizador através de um algoritmo, para que deste modo se aumente a eficiência da leitura dos sinais EMG.

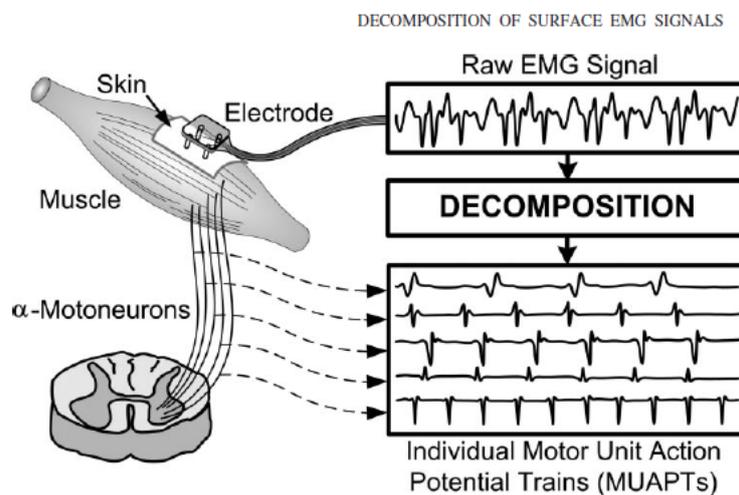


Figura 2.2. Esboço da captação e decomposição dos sinais EMG (Carlo J. De Luca, et.al, 2006).

A literatura sobre a temática de interfases dos sinais EMG diz-nos que estas são constituídas por três etapas:

- captação do sinal através dos vários elétrodos;
- processamento desse mesmo sinal;
- classificação dos padrões em tempo real.

A classificação dos padrões é feita de modo a poder aumentar a eficiência da leitura dos sinais EMG provenientes do utilizador, que consiste em registar os vários

valores obtidos para cada tipo de movimento da pessoa, criando um intervalo de valores para o respectivo movimento. Deste modo, cada movimento efetuado irá ter o seu padrão. Assim, sempre que o sinal EMG tenha um valor que esteja dentro de um intervalo de determinado padrão, o sistema conseguirá associar esse mesmo valor ao movimento desejado.

Por sua vez o processamento de sinais EMG é feito através de um processo com cinco etapas:

1. condições de sinal e pré-processamento;
2. captação de características dos sinais;
3. redução da dimensionalidade do sinal;
4. reconhecimento do padrão em que o sinal se enquadra;
5. aprendizagem *offline* e *online*.

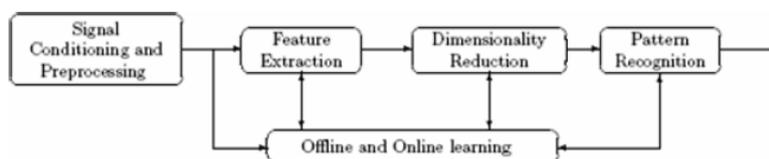


Figura 2.3. Esquema para a aquisição e análise de um sinal EMG (Federico Carpi e Danilo de Rossi).

Na primeira etapa, segundo Federico Carpi e Danilo de Rossi, existe um pré-processamento dos sinais de EMG de forma a reduzir a probabilidade de não se conseguir considerar todos os dados retirados dos sinais, assim tenta-se garantir que todos os dados recolhidos irão ser usados. Nesta etapa, também é realçado componentes espectrais, como por exemplo a transição do sinal EMG (Hudgins,1990), que contenham informação importante para a análise de dados. Além disso, esta etapa detecta o início do movimento e activa as etapas seguintes.

Na segunda etapa o objectivo é quantificar o sinal proveniente do utilizador, para tal são usados filtros de banda, que na opinião de Guanis de Barros Vilela Junior, podem ser circuitos analógicos, como por exemplo, amplificadores, resistores ou condensadores, ou podem ser *softwares* ou filtros digitais, tais como o algoritmo de

Butterwoth, ou o algoritmo de Chebyshev, resultando assim o comprimento de onda do sinal usado como o valor do sinal EMG (Kawasaki, Kayukawa, 2014). Outra forma de caracterizar o sinal segundo Federico Carpi, Danilo de Rossi, é determinar ao nível de activação muscular, cuja metodologia é semelhante.

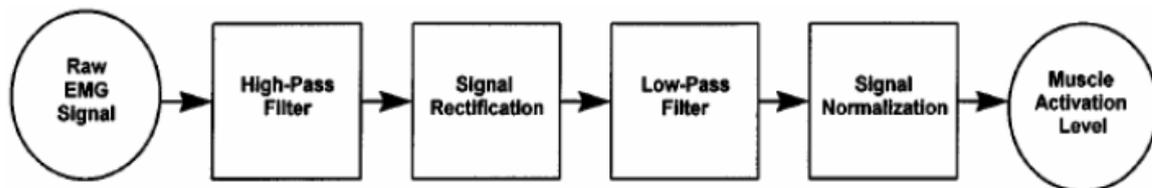


Figura 2.4. Diagrama de bloco de processamento de sinal EMG para detecção do nível de activação muscular (Federico Carpi e Danilo de Rossi).

Na terceira etapa, atendendo que os sinais de EMG são dados de grandes dimensões, o valor usado é calculado através de um integral linear, que vai usar cada segmento do sinal EMG (Kawasaki, Kayukawa, 2014), assim é necessário reduzir a sua dimensão, caso contrário seria bastante difícil mapeá-los. Através desta abordagem, consegue-se ter certeza que não se perde nenhuma informação, assim como remover todos os dados que possam interferir na leitura correta do sinal.

A quarta etapa consiste em identificar em que padrão de movimento se enquadra o valor obtido do sinal EMG, identificando assim o movimento que o sujeito pretende realizar.

Na perspectiva de Federico Carpi e Danilo de Rossi a quinta e última etapa existe, porque os padrões de sinais EMG variam de pessoa para pessoa, e, a mesma pessoa pode variar também os seus padrões de tempo a tempo, devido à impedância da pele, às variações das condições climatéricas (Chia-Fen Chi, et al, 2012), ao cansaço físico, à localização dos eléctrodos que se pode alterar devido ao suor ou tremores, ou mesmo simplesmente por estar doente. Por isso, de forma a tornar universal o processamento dos sinais EMG, a unidade de processamento deveria adaptar-se a estas variações de modo ao seu funcionamento manter-se constante, independentemente do estado físico da pessoa/sujeito. Deste modo, o aparelho deveria aprender como o utilizador se comporta e ajustar os seus parâmetros internos relativamente à variação ocorrida no utilizador em tempo real. Porém, a maioria dos dispositivos que estão no mercado apenas têm aprendizagem offline,

ou seja, o utilizador aprende a gerar alguns sinais e o dispositivo é sintonizado com esses sinais. Quando o utilizador deixa de conseguir manusear correctamente o dispositivo, tem que voltar ao centro de assistência e voltar a sintonizar o dispositivo.

2.1.1. Vantagens e desvantagens dos sinais EMG

A literatura sobre sinais EMG, diz-nos que estes têm as seguintes vantagens:

- podem ser registados através de métodos não invasivos;
- fornecem uma medida contínua da actividade muscular;
- podem ser usados para controlar dispositivos robóticos;
- têm uma harmonia que se situa no intervalo de 25 a 3k Hz e podem ter amplitudes aproximadamente entre $100\mu V$ e 90mV;
- dados com valores errados, devido ao movimento do utilizador, têm frequências muito baixas que podem ser filtradas de um modo eficiente sem alterar a informação útil dos sinais EMG.

Contudo também existem desvantagens nesta tecnologia:

- é necessário um grande esforço mental durante as primeiras etapas da fase de treino;
- ao usar eléctrodos superficiais para medir os sinais EMG, só se obtém boas leituras para músculos superficiais, sendo muito difícil obter leituras de músculos que estejam mais profundos na estrutura muscular dos membros;
- os eléctrodos ficam sujeitos à actividade eléctrica da área onde estão colocados;
- não conseguem providenciar nenhuma resposta ao utilizador.

Quanto há última desvantagem desta tecnologia, já estão a ser feitos estudos no sentido de realizar uma interface entre o sistema nervoso periférico do utilizador e o dispositivo artificial, para estimular o sistema nervoso periférico de uma maneira selectiva e registar os dados. Segundo Federico Carpi e Danilo de Rossi, recentes desenvolvimentos

na tecnologia de implantes electrónicos e na compreensão das funções dos nervos, tornaram possível fabricar interfaces neuronais selectivas que podem trocar informação entre o sistema nervoso e instrumentos artificiais computadorizados. Uma interface biocompatível neural pode restaurar alguma resposta sensorial ao utilizador, estimulando de maneira apropriada os nervos aferentes, como também permitir controlar uma prótese baseada em sinais EMG. Deste modo, quando o utilizador receber uma resposta sensorial devido à estimulação dos seus nervos aferentes, e a prótese for controlada directamente através dos nervos aferentes, o utilizador será capaz de "sentir" o dispositivo como uma parte do seu corpo.

2.2. Dispositivos controláveis a partir de sinais EMG

Uma das principais aplicações após se conseguir estimar os ângulos das articulações através de sinais musculares é o controlo de dispositivos robóticos. Nessa área já foram feitas várias investigações de modo a melhorar o controlo do dispositivo, por parte do utilizador, tornando o movimento do dispositivo em causa mais harmonioso e fluente, tentando assim que a utilização dos mesmos se torne mais prática.

2.2.1. Artigos científicos

2.2.1.1. “sEMG-based continuous estimation of joint angles of human legs by using BP neural network”

Neste artigo os autores (Feng Zhang, et al, 2012), propõem um método que consiste num modelo não linear que descreve a relação entre os sinais EMG e os ângulos das articulações de pernas humanas, em que uma simples rede neuronal com *backpropagation* é feita para a criação do modelo. Os dados de entrada do modelo são os sinais EMG após terem sido processados e os dados de saída são os ângulos da articulação da anca, joelho e tornozelo. De forma a comprovar a efectividade da rede neuronal com *backpropagation* participam neste estudo seis pessoas saudáveis e quatro pessoas com lesões na espinal medula. São feitos dois modos de movimento pelos indivíduos saudáveis, incluindo pedalar numa bicicleta estática e esticar as pernas a diferentes velocidades e com diferentes cargas, e apenas o exercício da bicicleta estática é seleccionado para os

indivíduos com lesão na medula espinal. São usados sete eléctrodos que são colocados de modo a registar os sinais EMG de sete músculos da perna e três ângulos das articulações da anca, joelho e tornozelo são captados simultaneamente. Os resultados deste estudo mostram que este método obtém uma boa performance na estimativa dos ângulos das articulações usando os sinais EMG, tanto para os utilizadores saudáveis tanto para os utilizadores com lesões na espinal medula. Este método pode ser aplicado em robôs de reabilitação ou na técnica de electroestimulação, baseada nos sinais EMG do utilizador, para uma reabilitação activa de indivíduos com lesões na espinal medula ou para aqueles que sofreram um AVC.

Comparativamente a métodos tradicionais de estimativa de ângulos de articulações através dos sinais EMG, o método proposto melhorou vários aspectos, tais como a precisão da estimativa, características em tempo real, características dinâmicas, a suavidade e a robustez dos movimentos.

Ao tirar proveito a informação dinâmica proveniente dos sinais EMG, além das suas amplitudes, este método é aplicável não só a indivíduos saudáveis, mas também é aplicável indivíduos com lesões na espinal medula ou para aqueles que sofreram um AVC, apesar de estes últimos terem sofrido um enfraquecimento muscular e os seus sinais EMG se terem tornado conseqüentemente mais fracos.

2.2.1.2. Metodologia

Tendo em conta que muitos indivíduos que têm lesões na espinal medula ou que sofreram um AVC, têm muito mais força muscular num lado do que no outro devido à sua lesão e tendo também em conta a simetria dos membros do corpo humano, os movimentos do membro do lado saudável puderam ser usados como sinal de controlo para o robô de reabilitação de modo a ajudar o membro do lado lesionado. Neste artigo tenta-se implementar um treino de reabilitação para os indivíduos que sofreram destas lesões e

tenham perdido capacidades motoras, para tal controlam-se os movimentos do membro do lado lesionado de forma a este seguir os mesmos movimentos do membro do lado saudável através de um robô de reabilitação para membros inferiores. Os movimentos do membro do lado saudável são estimados através dos sinais EMG em vez de usar instrumentos de medição de posição que são sempre inconvenientes e pesados.

Para tal este método divide-se em três etapas:

1. Captação de dados;
2. Processamento do sinal;
3. Aplicação da rede neuronal com *backpropagation* para a estimativa do ângulo.

No processamento do sinal, é de notar, que, de maneira a remover as interferências nos sinais EMG e o ruído do sinal, que podem criar dados errados, é utilizado um *notch filter* com 50 Hz e um *band-pass filter* com uma frequência de corte mínima de 20 Hz e com uma frequência de corte máxima de 500 Hz. Estes filtros são aplicados nos sinais EMG provenientes do utilizador para em seguida poderem ser processados.

Após o pré-processamento ser realizado, parte-se para o processamento de sinal em si.

Na terceira etapa os sinais EMG processados são usados para criar uma matriz de *inputs* e os ângulos das articulações processados são usados para criar uma matriz de *outputs*, mais concretamente a matriz alvo. Todos os dados são divididos em dois grupos, dados de treino e dados de validação. Durante a captação de sinais, 20 segundos de cada captação de sinal é extraído, 10 segundos para o treino e 10 segundos para a validação.

2.2.1.3. Outros artigos

A grande maioria dos *softwares* e seus dispositivos tem como base a metodologia apresentada na secção 2.2.1.2, porém existem autores que criaram dispositivos com outro tipo de capacidades.

No artigo “EMG-Based of a Robot Arm Using Low-Dimensional Embeddings” (Panagiotis K. Artemiadis and Kostas J. Kyriakopoulos, 2010) os autores propõem um novo meio de interface de controlo dos movimentos do membro superior, enquanto é registado de maneira superficial a actividade EMG dos músculos e esta é transformada em variáveis cinemáticas que vão ser usadas para controlar o braço robótico. A metodologia deste artigo baseia-se na premissa em que os músculos são activados colectivamente, formando sinergias musculares variáveis no tempo. Assim a activação muscular pode ser representada num espaço dimensional pequeno, onde as sinergias podem ser representadas em vez de activações individuais. Os autores sugerem que uma representação de baixa dimensão é fiável ao nível cinemático do braço, como por exemplo ao nível dos ângulos das articulações. Deste modo ao identificar as representações de baixa dimensão subjacentes das activações musculares e movimentos realizados, pode-se chegar a uma maneira mais robusta de decodificar os sinais EMG para os movimentos.

No artigo “*Teaching by Demonstration on Dual-arm Robot using Variable Stiffness Transferring*” (Chenguang Yang, et al., 2015) os autores usam a técnica de aprendizagem por demonstração em que usam um braço robótico em que o utilizador move juntamente com o seu braço de modo a que o sistema interprete melhor os sinais EMG do utilizador, bem como a intensidade do movimento que está a fazer.

No artigo “*Optimization of EMG-based hand recognition: Supervised vs. unsupervised data preprocessing on healthy subjects and transradial amputees*” (F. Riilo, et al., 2014) os autores usam a mesma metodologia correspondente a um sistema de reconhecimento de padrões, porém utilizam duas técnicas distintas de modo a comparar a técnica *Principal Component Analysis*, que é a técnica mais utilizada, com a técnica *Common Spacial Patterns*, uma vez que esta técnica tinha vindo a demonstrar algum potencial na temática de reconhecimento de padrões através de sinais EMG.

No artigo “*Quantification and solutions of arm movements effects on Semg pattern recognition*” (Jianwei Liu, et al., 2014) os autores comparam o efeito de o utilizador mexer ou não o braço, enquanto os sinais EMG são captados, na eficiência do

sistema reconhecer o tipo de gesto que está a ser realizado pelo utilizador. Para tal, usam a mesma metodologia e comparam a eficiência em cada caso e propõem que seja usado um treino com os dados de ambas as situações de modo a que haja um reconhecimento com uma maior eficiência.

No artigo “*Continuous estimation of finger joint angles under diferente static wrist motion from surface EMG signals*” (Lizhi Pan, et al., 2014) os autores começam por realizar um treino onde pedem ao utilizador que defina uma posição do pulso e que dobre e estique um dos seus dedos até onde conseguir, e repetem este processo para sete posições diferentes do pulso. De seguida utilizam um classificador de análise linear discriminante de forma a identificar qual é a posição em que se encontra o pulso do utilizador, de modo ao *software* conseguir um melhor reconhecimento da posição em que se encontram os dedos.

No artigo “*Distance and mutual information methods for EMG feature and channel subset selection for classification of hand movements*” (Haitham M. Al-Angari, et al. 2016) os autores têm como objectivo identificar quais são as melhores posições para colocar os eléctrodos no braço do utilizador de forma a que se consiga uma melhor classificação da posição da mão. Para tal usam dois métodos, o primeiro é o *distance-based feature selection* que determina um índice de separabilidade utilizando a distância entre classes de Mahalanobis. O segundo método usado é o *correlation-based feature selection*, que vai medir a quantidade de informação mútua entre as *features* usadas e as respectivas classes.

2.3. Features

Ao percorrer a literatura sobre dispositivos controláveis a partir dos sinais EMG verifica-se que a grande maioria usa o mesmo método de estimativa dos ângulos das articulações apresentado no artigo “*sEMG-based continuous estimation of joint angles of human legs by using BP neural network*” (Feng Zhang, et al, 2012). O que os vai distinguir é a fase de treino, em que se pode variar o número de repetições dos movimentos pretendidos e as suas velocidades, e , principalmente, as *features* que são retiradas dos sinais EMG, de modo a usar esses valores como dados de entrada na rede neuronal que irá ser usada para dar a estimativa dos ângulos das articulações em causa.

De forma a pudermos usar uma metodologia de criação de padrões de movimento é necessário conseguirmos quantificar o valor dos sinais EMG que o utilizador produz, para tal são usadas *features*.

De modo a quantificar essas *features* (Harahisa Kawasaki, et al, 2014), propõe que os sinais EMG provenientes do utilizador sejam medidos com uma frequência de amostragem de 1000 Hz, em seguida os sinais devem passar por um filtro de banda com uma largura de banda na ordem dos 10 a 450 Hz. Depois deve-se segmentar os dados de saída, provenientes do filtro de banda, em deslocamentos com comprimentos de 32 ms e deslocamentos de *frame* de 256 ms. Um comprimento de onda é calculado através de um integral linear, que vai usar cada segmento do sinal EMG. O valor obtido para este comprimento de onda vai ser usado como o valor característico do sinal EMG.

Outro método de retirar o valor característico dos sinais EMG é ter apenas em consideração os dados dos 4,5 segundos centrais em cada 5 segundos de cada movimento, é que serão usados para análise, de modo a remover os estados transientes do movimento. Em seguida os dados serão segmentados em séries de janelas de 200 ms com 75% de sobreposição e as características dos sinais EMG vão ser retiradas de cada uma dessas janelas (Jianwei Liu, et al, 2014). O *Hudgins time domain set* e o coeficiente auto-regressivo são duas das *features* mais usadas nos sinais EMG e ,como tal, o seu papel no reconhecimento dos padrões dos sinais EMG é similar. Porém, tendo em conta que o coeficiente auto-regressivo é a dimensional, foi seleccionado em detrimento do *Hudgins time domain set*, uma vez que é o que consegue definir melhor o *mean centroid bias*.

Em intervalos de tempo curto, cerca de 0.1 segundos a 0.3 segundos, pode-se fazer uma aproximação do tempo de série dos sinais EMG usando um processo Gaussiano estacionário, e assim podemos modelar o sinal EMG através da seguinte equação:

$$s(n) = \sum_{i=1}^P a_i s(n-i) + e(n) \quad (2.1)$$

Para este método é seleccionado um p com um valor de 6 e 6 coeficientes AR como *feature* para cada canal dos sinais EMG. Além disso, a dimensão do vetor de dimensão por cada *frame* dos sinais EMG é de 36, devido a serem usados elétrodos de 6 canais. Por fim, um vetor com uma dimensão de 36 é gravado no espaço característico dos sinais EMG.

No artigo "*Biomedical Signal Processing and Control*" (Haitham M. Al-Angari, et al, 2016), usam *features* dos sinais EMG diferentes de forma a processarem os dados provenientes dos mesmos sinais. Os autores propõem que o sinal seja filtrado por um filtro *BPF Butterworth* de sexta ordem e que seja segmentado em janelas de 250 ms com uma sobreposição de 225 ms .

Foram extraídas 10 características em cada uma destas janelas:

- Valor médio absoluto;
- Desvio standard;
- Comprimento de onda;
- Energia;
- Passagens por zero;
- Mudança da inclinação do sinal;
- Factor de auto-regressão;
- Decomposição de *wavelet*;
- Decomposição diferencial de *wavelet*;
- Entropia de amostra.

Tabela 2.1. Fórmulas de *features*.

	<i>Feature</i>	Fórmula
1	Valor Médio Absoluto	$MAV = \frac{1}{n} \sum_{k=1}^n x_k $
2	Desvio Standard	$SD = \sqrt{\frac{1}{n} \sum_k (x_k - \mu)^2}$
3	Comprimento de onda	$WL = \sum_{k=1}^n \Delta x_k $
4	Energia	$EN = \sum_{k=1}^n x_k ^2$
5	Passagem por zero	$sgn = (-x_k \times x_{k+1}) \text{ e}$ $ x_k - x_{k+1} \geq \text{limite}$ $sgn(x) = 1 \text{ se } x > 0$ $\text{caso contrário } sgn(x) = 0$
6	Mudança da inclinação do sinal	$(x_k - x_{k-1}) \times (x_k - x_{k+1}) \geq \text{limite}$
7	Factor de auto-regressão	$x_k = \sum_{i=1}^P a_i x_{k-i} + e_n$

A decomposição de *wavelet* vai consistir em avaliar cada nível de decomposição do sinal.

A decomposição diferencial de *wavelet* vai ser computada de modo a dividir cada segmento em dois e calcular a diferença da decomposição de *wavelet* entre as duas metades de cada segmento.

Por sua vez, no artigo "*Optimization of EMG-based hand gesture recognition: Supervised vs. Unsupervised data processing on healthy subjects and transradial amputees*" os autores optam também por usar a técnica de janelas com sobreposição, em que dividem os sinais EMG provenientes do utilizador em janelas com 300 ms, com 75 ms de atraso entre duas janelas com sobreposição consecutivas. A duração das janelas foi seleccionada de modo a cumprir os requisitos necessários a aplicações que funcionam em tempo real. As *features* são retiradas de cada janela, e as características usadas neste método foram (F. Riillo, et. al, 2014):

- Média;
- Raiz quadrada da média;
- Amplitude *Willison*;
- Mudança da inclinação do sinal;
- Integral de raiz simples;
- Variância;
- Comprimento de onda.

• **Tabela 2.1.** Fórmulas de *features*.

	<i>Feature</i>	Fórmula
1	Média	$M = \frac{1}{n} \sum_{k=1}^n x_k$
2	Raiz quadrada da média	$RMS = \sqrt{\frac{1}{n} \sum_{k=1}^n x_k^2}$
3	Amplitude Willison	$WA = \frac{1}{n} \sum_{k=1}^{n-1} f(x_k - x_{k+1})$ $f(x) = 1 \text{ se } x \geq \text{limite}$ $\text{caso contrário } f(x) = 0$
4	Integral de raiz simples	$SSI = \sum_{k=1}^n x_k^2$
5	Variância	$V = \frac{1}{n-1} \sum_{k=1}^n (x_k - M)^2$

2.4. Filtros digitais

Os filtros digitais têm uma papel muito importante em sistemas de captação de sinais, pois têm a capacidade de remover frequências seleccionadas e remover ruído do sinal captado (Teache Note ADInstruments Pty Ltd). Ao passo que as configurações certas dos filtros podem aumentar a visibilidade de um efeito do sinal, as configurações incorrectas podem distorcer a apresentação do sinal ou até mesmo remover um efeito do sinal. Deste modo é importante compreender o conceito de filtragem de dados.(NDT Resource Center).

A filtragem de sinal é aplicada aos dados recebidos e, por isso, não está directamente relacionada com a frequência do dispositivo de captação de dados .(NDT Resource Center)

Considere-se que um dispositivo de captação de dados detecta um entalhe por 1/60 de segundo. Num período de 1 segundo o dispositivo pode, em teoria, passar 60 vezes por esse entalhe, o que faz com que a frequência do entalhe seja de 60 Hz. Porém esse entalhe pode ter surgido devido a várias razões, tais como, o dispositivo se

ter movido, pode ser ruído eléctrico, pode ser uma mudança de condutividade ou por outros factores que ocorrem a frequências diferentes das dos dados que queremos captar. (NDT Resource Center)

2.4.1. Vantagens e desvantagens

Os filtros digitais são usados após a captação de dados e como tal têm a vantagem de:

- Podermos criar filtros digitalmente que seriam impossíveis de criar de forma analógica;
- Serem estáveis ao longo do tempo e fornecem um sinal filtrado consistente e reproduzível;
- Podermos criar gráficos em que podemos comparar os dados filtrados com os dados originais que são retidos.

Porém a desvantagem é que os filtros digitais, têm que ser usados também antes da digitalização, senão qualquer ruído presente no sinal irá ser amplificado e irá ter um impacto negativo no resultado final do sinal filtrado. (Teache Note ADInstruments Pty Ltd)

2.4.2. Terminologia

De modo a perceber-se o básico sobre filtragem de sinais, é necessário conhecer alguns termos que são usados para definir características de filtros. (Teache Note ADInstruments Pty Ltd)

- *Frequência de corte*: é a frequência ou frequências que definem o limite do filtro. É o ponto de corte desejável para o filtro;
- *Stop Band*: É a gama de frequências que são filtradas para fora;
- *Pass Band*: É a gama de frequências que consegue passar pelo filtro e são guardadas;
- *Transition Band*: É a gama de frequências que se situa entre a *Stop Band* e a *Pass Band*.

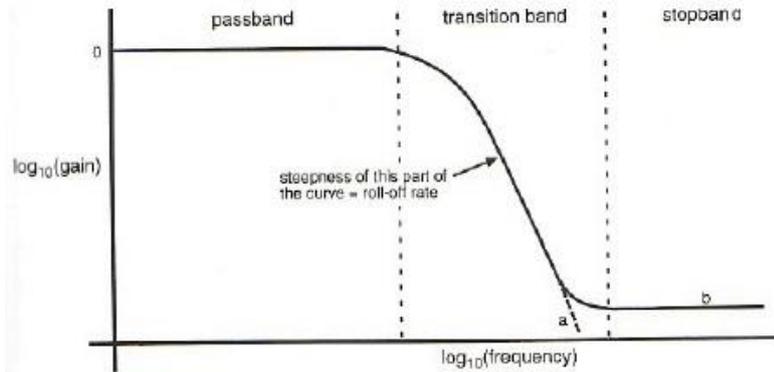


Figura 2.5. Bandas de filtro (S.S. Young,2001).

Todas as frequências do sinal que estão abaixo da frequência de corte são designadas como *pass band*, e todas as frequências que estão acima da frequência de corte são designadas de *stop band*. A região entre a *pass band* e a *stop band* é conhecida por *transition band* ou *transition width*. Esta largura, que é definida em Hz, depende de quanto a resposta do filtro desce abruptamente a partir da *pass band* até à *stop band*. Esta descida é relacionada com a taxa de *roll-off*.(Teache Note ADInstruments Pty Ltd)

2.4.3. Tipos de filtro digital

Os dois filtros mais usados são designados como *LowPass Filter* e *High Pass Filter*. Por vezes é também usado um filtro designado como *Band Pass Filter*, que é a combinação do *LowPass Filter* e do *High Pass Filter*. Os filtros são ajustados em Hz.

- *LowPass Filter*: permite que frequências baixas passem e retira as frequências mais altas, ou seja, todas as partes do sinal que mudam rapidamente (têm um elevado declive) são filtradas, como por exemplo o ruído eléctrico;
- *High Pass Filter*: permite que as frequências altas passem e retira as frequências mais baixas, ou seja, filtra as alterações de sinal que ocorrem ao longo de um tempo significativo;

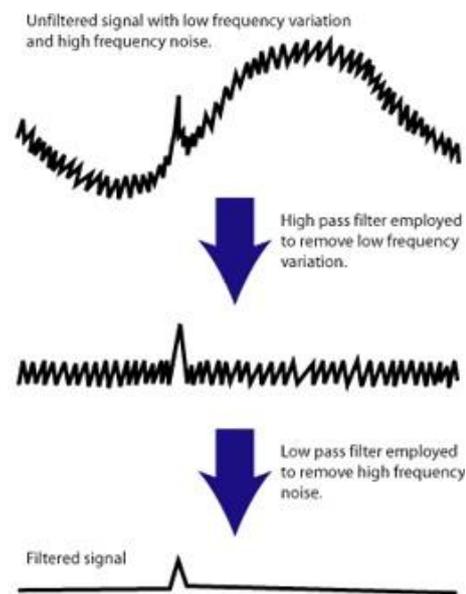


Figura 2.6. Efeito de um *High pass filter* e de um *Low pass filter* num sinal (NDT Resource Center).

Na figura 2.9., as mudanças graduais do sinal (frequências baixas), são filtradas primeiro, através de um *High Pass Filter*, em seguida as frequências altas, provenientes de ruído eléctrico, são filtradas através de um *LowPass Filter*, de modo a deixar visível um indicador de falha no sinal. De notar que os indicadores de falha no sinal são compostos por várias frequências, e ambos os filtros têm a tendência de diminuir a intensidade do sinal de indicação. Adicionalmente, a velocidade de verificação tem que ser controlada quando se usam filtros. Se se passar por uma falha muito lentamente o *High Pass Filter* pode filtrar esse indicador de falha, mas se se passar por uma falha muito rapidamente o *LowPass Filter* poderá eliminar o indicador de falha.

- *Notch Filter*: remove uma determinada frequência no sinal, dentro de um intervalo (um *notch filter* de 50 Hz, pode bloquear sinais de 49,5 Hz a 50,5 Hz);
- *Narrow Band-Pass Filter*: são usados para remover todas as frequências do sinal que se encontrem fora de um pequeno intervalo de frequências seleccionado, por exemplo, de 8 Hz a 12Hz. Todas as frequências que se encontrem fora desse intervalo não passarão no filtro;

- *Band-Pass Filter*: tem a mesma função que o *Narrow Band-Pass Filter*, porém este filtro é usado para quando o intervalo de frequências desejado é maior, por exemplo de 0 Hz a 100 Hz;
- *Band-Stop Filters*: são usados para remover frequências que se encontram dentro de um intervalo e registrar apenas os sinais que tenham frequências que estejam fora do intervalo seleccionado, por exemplo num intervalo de 16 Hz a 32 Hz o filtro irá gravar apenas sinais que tenham frequências de 0 Hz a 15 Hz e de 33 Hz até à frequência do sinal captado.

3. DEFINIÇÃO DO PROBLEMA

Como foi referido no capítulo 1, o objectivo deste trabalho é desenvolver um *software* que consiga reconhecer gestos da mão do utilizador através dos seus sinais EMG.

3.1. Equipamento de captação de sinais EMG

De forma a captar os sinais EMG do utilizador enquanto este faz um determinado gesto é usado o dispositivo *Myo Gesture Control* produzido pela *Thalmic Labs* figura 3.1. É este dispositivo que vai permitir digitalizar os sinais EMG, de modo a puderem ser tratados e analisados.



Figura 3.1. Pulseira *Myo Gesture Control*.

3.1.1. Equipamento e Características do *Myo Gesture Control*

Além da pulseira *Myo Gesture Control*, este equipamento vem com um adaptador *Bluetooth*, um cabo USB e dez cliques de modo a encurtar o seu perímetro circular, caso o utilizador tenha um antebraço com um perímetro inferior a 19 cm.



Figura 3.2. Conjunto *Myo Gesture Control*.

A pulseira tem um perímetro que pode variar, dependendo do utilizador, que pode ir de 19 cm a 34 cm. Tem um peso de 93 gramas e uma espessura de cerca de 2 cm. É compatível com *Windows*, *Mac*, *IOS* e *Android*. É constituído por oito eléctrodos, que funcionam separadamente, e incorporam sensores EMG e nove eixos IMU que são compostos por um giroscópio de três eixos, um acelerómetro de três eixos e um magnetómetro de três eixos. Tem um processador *ARM Cortex M4*, e ainda tem a capacidade de vibrar como resposta à sua utilização. Vem com um adaptador *Bluetooth Smart Wireless Technology*, o que faz com que este dispositivo tenha a capacidade de funcionar sem fios. Tem uma bateria interna com a capacidade de funcionamento de aproximadamente 24 horas, e para se recarregar a bateria é usado o cabo USB. De considerar ainda que os sinais capturados por este dispositivo têm uma frequência de 200 Hz.

3.1.2. Preparação do *Myo Gesture Control*

A primeira etapa antes de se começar a trabalhar com este dispositivo é instalá-lo, num computador com acesso à internet, fazendo uso do seu cabo USB. A partir do momento que o dispositivo está correctamente instalado podemos usar o adaptador *bluetooth*, de modo a pudermos utilizar a sua função de *wireless*.

Antes de a utilização deste dispositivo por parte de um novo utilizador é necessário “aquecê-lo”, ou seja, o utilizador tem que usar o dispositivo ligado durante alguns minutos antes de o poder usar correctamente. Em seguida o utilizador terá que calibrar o dispositivo tal como o *software*, previamente instalado, nos indica, para tal o utilizador tem que realizar os cinco gestos que o *Myo* já reconhece, figura 3.3.



Figura 3.3. Gestos a realizar para a calibração do *Myo Gesture Control*.

Após o *software* nos indicar que a calibração foi efectuada, o dispositivo está pronto a ser usado.

3.2. Filtro digital

Os sinais EMG captados contêm algum ruído, proveniente de vários tipos de situações, tal como referido na secção 2.4. Usando os sinais com ruído irá provocar uma queda no coeficiente de eficiência do reconhecimento do gesto, uma vez que estaríamos a usar dados que não seriam provenientes exclusivamente dos sinais EMG do utilizador. Deste modo, de forma a eliminar o maior número de dados indesejáveis irá ser aplicado um filtro digital depois de os sinais EMG serem captados.

O tipo de filtro seleccionado foi um *Low Pass Filter*, uma vez que usando o *Myo Gesture Control* não existirá o problema dos eléctrodos se deslocarem, durante o movimento realizado pelo utilizador, pois durante o movimento o braço está apoiado e imóvel. Desta forma o ruído proveniente do sinal é ruído eléctrico, portanto não há necessidade de se aplicar um *Band Pass Filter*, poupando assim algum esforço computacional.

Este filtro foi realizado através do programa MATLAB, e para tal foram seleccionados as seguintes características:

- Frequência do sinal;
- Frequência de corte;
- Ordem do filtro;
- Parâmetros do filtro.

A aplicação do filtro em causa está demonstrada na figura 3.4. A primeira etapa é rectificar os sinais captados, o que é conseguido através da linha 6 do código.

```

5 - original_EMG1 = (emg1);%,emg2,emg3,emg4,emg5,emg6,emg7,emg8);
6 - Rectified_EMG1 = abs(original_EMG1);
7
8 - Fe=200; %Frequência do sinal
9 - Fc=2; % Frequência de corte (de 2 Hz a 6 Hz dependendo do tipo de eléctrodo usado)
10 - N=6; % Ordem do filtro
11 - [B, A] = butter(N,Fc*2/Fe, 'low'); %Parâmetros do filtro
12 - femg1=filtfilt(B, A, Rectified_EMG1);
    
```

Figura 3.4. Código do *Low Pass Filter* em MATLAB.

De seguida, é dado a frequência do sinal captado, linha 8. Depois é seleccionada a frequência de corte, linha 9. É escolhida uma frequência de corte de 2 Hz, uma vez que é a frequência de corte que apresenta um melhor resultado, devido a suavizar mais o sinal figura 3.5.

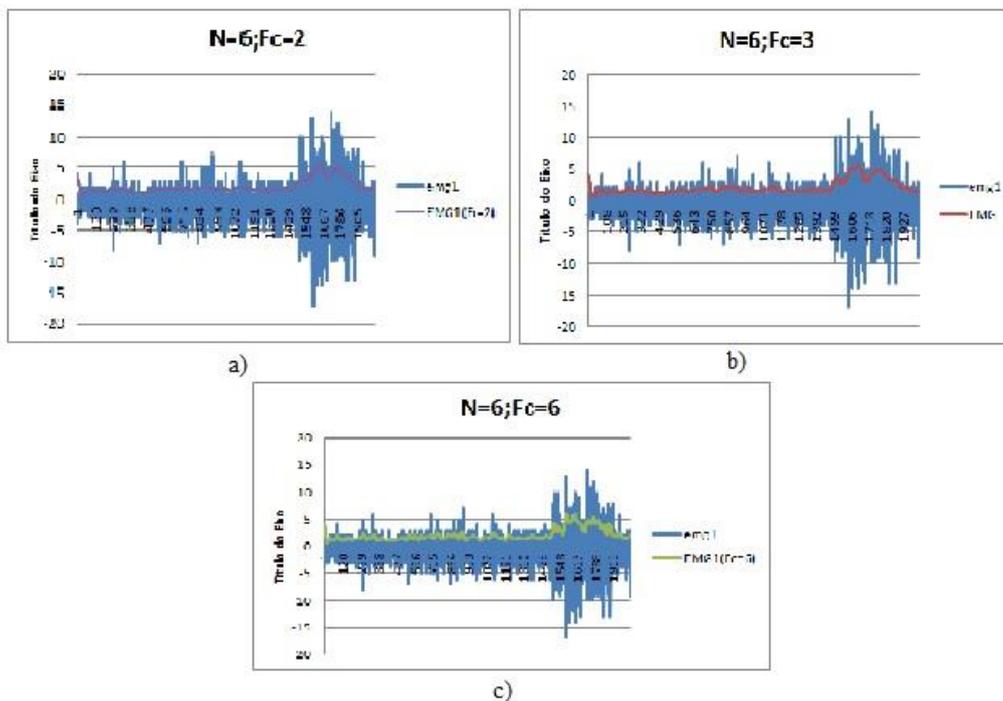


Figura 3.5. Sinal filtrado com uma ordem de 6 e com a frequência de corte a variar; a) Resultados do *Low Pass Filter* com uma frequência de corte de 2 Hz; b) Resultados do *Low Pass Filter* com uma frequência de corte de 3 Hz; c) Resultados do *Low Pass Filter* com uma frequência de corte de 6 Hz;

A ordem do filtro seleccionada foi de 6, por defeito, uma vez que esta característica não altera significativamente os resultados, tal como mostra a figura 3.6.

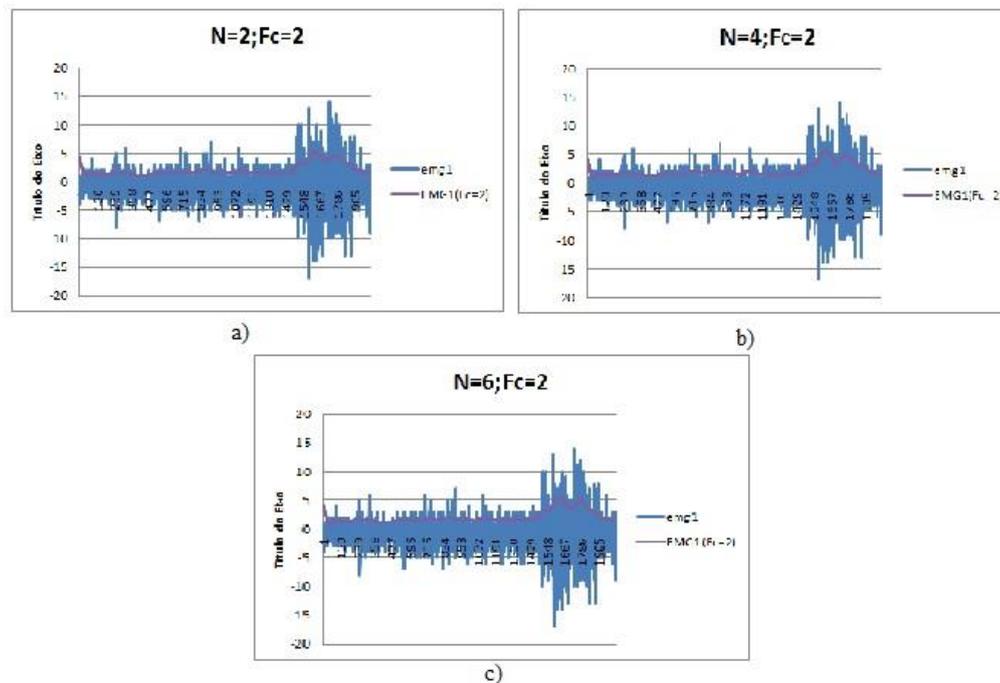


Figura 3.6. Sinal filtrado com uma frequência de corte de 2 hz e com a ordem do filtro a variar;
a) Resultados do *Low Pass Filter* com uma ordem de filtro 2; b) Resultados do *Low Pass Filter* com uma ordem de filtro 4; c) Resultados do *Low Pass Filter* com uma ordem de filtro 6;

Os parâmetros do filtro seleccionados estão representados na linha 11 da figura 3.4., e correspondem respectivamente à ordem do filtro N , e ao dobro da frequência de corte F_c a dividir pela frequência do sinal F_e . A função *butter* cria um filtro *low-pass*, *high-pass*, *band-pass* ou *band-stop*, dependendo do que seleccionarmos e do número de elementos que são colocados na terceira posição.

Por fim, na linha 12 aplica-se a função *filtfilt*, que consiste em processar os dados *Rectified_EMG1*. O vector B fornece os coeficientes do numerador do filtro e o vector A fornece os coeficientes do denominador. Depois de filtrar os dados no sentido crescente, a função inverte a sequência dos dados e volta a executá-los através do filtro. Os resultados obtidos através desta função têm as seguintes características:

- Distorção de fase zero;
- A função de transferência do filtro é igual à raiz quadrada da magnitude da função de transferência original do filtro;

- Uma ordem de filtro que é o dobro da ordem do filtro, que é especificada por B e A.

3.3. Matriz alvo

A matriz alvo tem o objetivo de fornecer a informação à rede neuronal do tipo de movimento que está presente em determinados sinais de EMG.

Neste trabalho cada gesto foi dividido em três tipos de movimentos diferentes:

- Posição inicial da mão;
- Início do movimento;
- Fim do movimento.

De forma a identificar estes três tipos de movimento em cada gesto foram analisados os sinais EMG captados e foram tidos em consideração vários aspetos:

- Seleccionar o eléctrodo onde se consiga uma melhor visualização dos momentos onde existe actividade muscular;
- Os valores mais baixos referem-se à posição inicial da mão;
- Quando existe um aumento constante dos sinais EMG, significa que o gesto está a ser inicializado;
- Quando existe um decréscimo constante dos sinais EMG, significa que o gesto está a ser finalizado;
- A partir de o momento em que se consiga fazer a divisão dos movimentos através dos sinais de um eléctrodo, esta divisão pode ser extrapolada para os restantes eléctrodos que apresentam piores resultados, pois todos os eléctrodos captam o mesmo gesto.

Para cada movimento foi associado um vetor e um valor correspondente como se pode ver na figura 3.7.

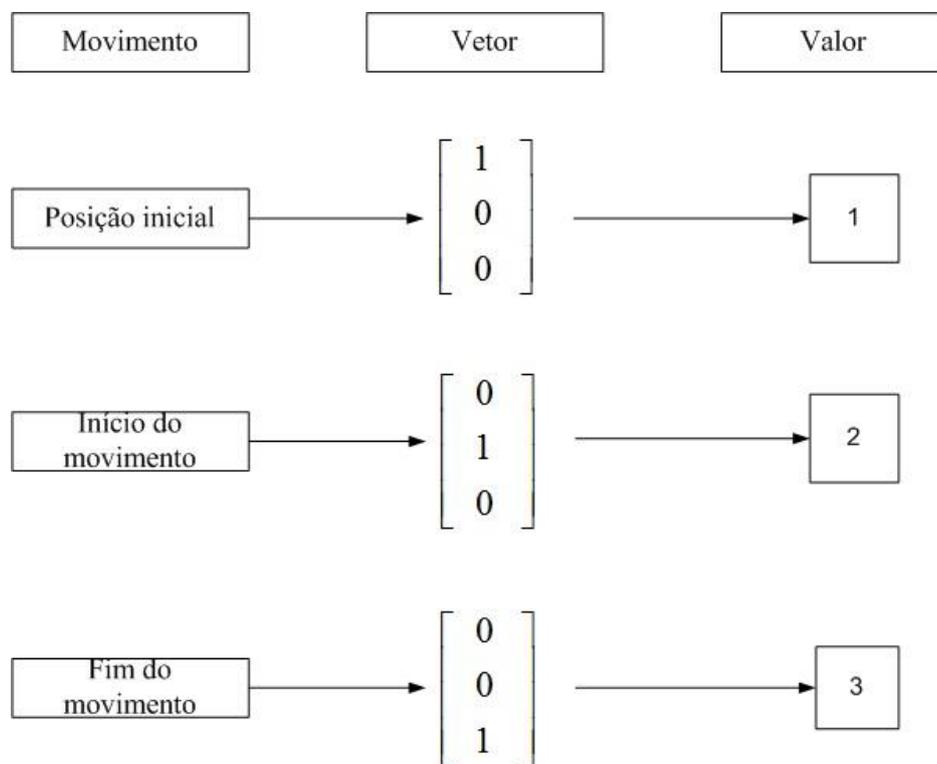


Figura 3.7. Vetores para cada movimento e respectivo valor.

Depois de se dividir cada gesto nos três tipos de movimento, é necessário criar a matriz alvo, para tal cada movimento terá um vector e um valor associado, que será inserido nos *inputs* em conjunto com os dados provenientes da captação dos sinais EMG do utilizador como mostra a figura 3.8.

id	A	B	C	D	E	F	G	H	I	tipo_gesto
1	emg1	emg2	emg3	emg4	emg5	emg6	emg7	emg8		
2	-4	-10	-6	-23	-2	0	0	-1	1	
3	1	10	-3	7	-2	-1	0	-1	1	
4	0	-3	6	0	0	-1	1	0	1	
5	-1	-4	-8	0	-1	-1	-1	0	1	
6	-1	0	0	2	-2	-2	-2	0	1	
7	-3	-4	-4	12	0	-1	-2	-1	1	
8	0	1	0	-3	0	1	0	0	1	
9	-1	0	-1	-2	0	-1	-1	-2	1	
10	0	0	-1	9	1	0	0	0	1	
11	-2	-3	3	7	-2	-1	-1	0	1	
12	0	0	-6	-17	1	-2	-1	-2	1	
13	-1	0	3	7	0	-1	0	-1	1	
14	0	0	-1	1	-2	0	-1	-1	1	
15	-1	-1	2	-5	-3	-2	0	0	1	
16	1	0	-2	4	-3	-2	-1	0	1	
17	0	2	-5	11	4	-1	1	0	1	
18	-1	-2	6	7	0	-1	-1	-2	1	
19	0	-1	0	-7	0	0	1	-2	1	
20	-1	-1	-3	-4	-2	2	-2	-2	1	
21	-3	-5	-2	-9	-3	-1	-2	-3	1	
22	0	2	1	4	-3	-2	-2	-1	1	
23	1	1	8	2	-1	0	-2	1	1	
24	-2	-3	-7	-1	-2	-1	0	-2	1	
25	-1	-1	-3	-5	-1	1	-1	-1	1	
26	-3	-3	1	5	-3	-3	-2	-2	1	
27	1	-3	-13	-23	1	-1	-1	0	1	

id	A	B	C	D	E	F	G	H	I	tipo_gesto
469	-2	-3	-1	-8	1	1	0	-4	1	
470	-1	-1	-2	7	3	0	-2	0	1	
471	0	0	-6	6	-2	-2	-1	2	2	
472	-2	-1	3	2	-1	-1	-2	0	2	
473	-2	-3	-8	24	5	-2	-3	-1	2	
474	0	0	-2	-18	-2	-1	1	0	2	
475	-1	-2	-1	3	-4	-2	-3	-1	2	
476	-1	-1	-1	7	5	2	1	-1	2	
477	0	-1	2	-7	-4	-3	0	0	2	
478	0	2	1	16	3	1	-1	-3	2	
479	1	-2	-6	-16	-2	1	2	0	2	
480	-2	-1	3	-14	-4	-3	-1	-3	2	
481	-1	0	-5	9	3	0	0	-1	2	
482	-2	-1	4	-3	-1	-2	-1	1	2	
483	-1	0	4	0	-1	-1	0	-1	2	
484	2	2	1	10	0	1	-1	-1	2	
485	-2	-4	-7	-12	-5	0	1	-1	2	
486	1	4	4	9	-2	1	0	2	2	
487	-2	-5	-17	-22	2	0	0	-1	2	
488	-2	-3	-4	-6	-1	-2	-2	-1	2	
489	1	4	1	13	1	1	0	0	2	
490	-1	0	9	-24	-3	-1	-1	-3	2	
491	-1	-3	2	36	2	-1	0	-1	2	
492	0	-1	-3	-10	2	-1	1	0	2	
493	1	-1	-5	-8	-7	-3	-1	0	2	
494	0	-1	-6	-3	-4	-1	-1	-2	2	
495	-4	-4	1	-20	-4	-2	-3	-3	2	

a)

id	A	B	C	D	E	F	G	H	I	tipo_gesto
722	4	1	13	-7	-50	-7	-11	-19		
723	-8	-20	8	18	32	47	5	-1	2	
724	1	7	-2	1	78	-35	-4	-5	2	
725	-4	-6	-14	-10	-36	-33	-1	-9	2	
726	-5	11	44	15	53	72	6	-34	2	
727	9	9	-41	-9	-8	-20	11	24	3	
728	4	-5	87	34	-7	-18	-12	36	3	
729	-2	12	-14	-22	11	19	-4	-35	3	
730	2	1	-49	10	28	54	23	7	3	
731	-11	-13	20	-1	-37	-30	-16	-10	3	
732	-4	5	-54	-29	-5	-3	13	3	3	
733	4	-5	40	20	9	-2	-1	-5	3	
734	5	13	2	-18	-8	57	-7	-16	3	
735	-6	-15	-7	13	62	-41	-10	16	3	
736	6	8	-37	-13	-39	-3	7	14	3	
737	0	-11	13	2	21	29	-6	-17	3	
738	0	16	-22	4	71	34	20	17	3	
739	-3	-29	58	12	-36	-35	-14	-12	3	
740	1	-13	-25	-2	-11	-53	-5	26	3	
741	3	15	-27	-5	-42	-44	-6	-6	3	
742	-5	-7	20	-15	-3	8	10	10	3	
743	4	15	-30	-21	0	-45	-13	-29	3	
744	-13	-5	-38	-19	4	40	-20	-52	3	
745	-3	-34	83	40	-7	9	3	24	3	
746	2	-8	-14	7	15	-37	10	41	3	
747	1	14	-1	-12	-29	41	5	3	3	
748	3	7	-9	-20	-2	2	4	-24	3	

b)

id	A	B	C	D	E	F	G	H	I	tipo_gesto
722	4	1	13	-7	-50	-7	-11	-19		
723	-8	-20	8	18	32	47	5	-1	2	
724	1	7	-2	1	78	-35	-4	-5	2	
725	-4	-6	-14	-10	-36	-33	-1	-9	2	
726	-5	11	44	15	53	72	6	-34	2	
727	9	9	-41	-9	-8	-20	11	24	3	
728	4	-5	87	34	-7	-18	-12	36	3	
729	-2	12	-14	-22	11	19	-4	-35	3	
730	2	1	-49	10	28	54	23	7	3	
731	-11	-13	20	-1	-37	-30	-16	-10	3	
732	-4	5	-54	-29	-5	-3	13	3	3	
733	4	-5	40	20	9	-2	-1	-5	3	
734	5	13	2	-18	-8	57	-7	-16	3	
735	-6	-15	-7	13	62	-41	-10	16	3	
736	6	8	-37	-13	-39	-3	7	14	3	
737	0	-11	13	2	21	29	-6	-17	3	
738	0	16	-22	4	71	34	20	17	3	
739	-3	-29	58	12	-36	-35	-14	-12	3	
740	1	-13	-25	-2	-11	-53	-5	26	3	
741	3	15	-27	-5	-42	-44	-6	-6	3	
742	-5	-7	20	-15	-3	8	10	10	3	
743	4	15	-30	-21	0	-45	-13	-29	3	
744	-13	-5	-38	-19	4	40	-20	-52	3	
745	-3	-34	83	40	-7	9	3	24	3	
746	2	-8	-14	7	15	-37	10	41	3	
747	1	14	-1	-12	-29	41	5	3	3	
748	3	7	-9	-20	-2	2	4	-24	3	

c)

Figura 3.8. Informação do tipo de gesto presente a cada frame: a) dados dos sinais EMG e respetivo valor do primeiro movimento ; b) dados dos sinais EMG e respetivo valor do segundo movimento ; c) dados dos sinais EMG e respetivo valor do terceiro movimento;

A matriz alvo é gerada através do código em MATLAB representado na figura 3.9.

```

1 -   ttargets=zeros(length(g)-1-sliding_window_size,3);
2 -
3 -   b=1;
4 -   for i = 1 : length(emg1) - sliding_window_size
5 -       if isequal(tipo_gesto(i) , 1) % posição inicial
6 -           ttargets(b , 1) = 1;
7 -       elseif isequal(tipo_gesto(i) , 2) % início do movimento
8 -           ttargets(b , 2) = 1;
9 -       elseif isequal (tipo_gesto(i) , 3) % fim do movimento
10 -           ttargets(b , 3) = 1;
11 -
12 -       end
13 -       b=b+1;
14 -   end

```

Figura 3.9. Código MATLAB para a criação da matriz alvo.

Na linha 1 foi definida a dimensão da matriz alvo, em que se tem que assegurar que esta matriz terá a mesma dimensão que a *feature*, e terá três colunas, uma vez que só existem três tipos de movimentos. Na linha 5 é iniciado um ciclo *for*, de modo a gerar a matriz alvo, que consiste em correr todos os dados provenientes dos sinais EMG do utilizador. Este ciclo consiste em ir à coluna “tipo_gesto” e analisar qual o valor que está presente em cada *frame*, se o valor for 1, então o vector nesse *frame* será o vector correspondente à posição inicial, se o valor for 2, então o vector nesse *frame* será o vector correspondente ao início do movimento e se o valor for 3, o vector nesse *frame* será o vector correspondente ao fim do movimento. À medida que se vai identificando qual o vector correspondente para cada *frame*, os vectores vão sendo concatenados de forma a que no final do ciclo esteja formada uma matriz, que vai ser a matriz alvo.

3.4. Feature e Sliding Window

Como é referido no capítulo 2.3, é necessário a utilização de *features* de modo a que se consiga identificar o tipo de gesto executado pelo utilizador. Neste trabalho a *feature* utilizada é o comprimento de onda e a dimensão da *sliding window* é de 20 *frames*, tendo em conta que este trabalho é baseado no artigo “*Learning System for Myoelectric Prosthetic Hand Control by Forearm Amputees*” (Haruhisa Kawasaki, et al 2014).

A fórmula do comprimento de onda está representada na tabela 2.2, e esta fórmula consiste em fazer o somatório da diferença de dados consecutivos em valor absoluto, $|\Delta x_k|$, que se situem dentro do conjunto de dados da *sliding window*, n .

A *feature* foi implementada através do programa MATLAB como mostra a figura 3.10.

```
33 function [soma] = codigo(dados , sliding_window_size)
34     w=sliding_window_size;
35     nframes = length(dados);
36     g=zeros(length(dados) - 1,1);
37
38     motion=zeros(w,1);
39     soma=zeros(length(g)-1-sliding_window_size,1);
40     for i=2:nframes
41
42         g(i-1)=dados(i)-dados(i-1);
43
44     end
45
46     b=1;
47     for i = 1 : nframes - sliding_window_size
48
49         motion(1:sliding_window_size , 1) = g(i : i + sliding_window_size - 1 , 1);
50
51         soma(b,1) = abs(sum(motion,1));
52
53         b=b+1;
54     end
55
56 end
```

Figura3.10. Código em MATLAB para o calculo da *feature*

De forma a implementar a *feature* é criada uma função, linha 33, que nos irá devolver o valor da *feature* correspondente aos dados obtidos para cada eléctrodo. Na linha 34 é definida a dimensão da *sliding window*, que é definida pelo utilizador. Para a realização deste trabalho, foi seleccionada uma dimensão de 20, devido a estar a seguir-se o artigo "Learning Systems for Myoelectric Prosthetic Hand Control by Forearm Amputees" (Haruhisa Kawasaki, et al. 2014). Na linha 36 é definida a dimensão do vector g , que será o vector onde se irá guardar os resultados das diferenças de dados consecutivos. Na linha 39 é definido o comprimento da *feature*. Chegando à linha 40, é criado um ciclo *for*, de modo a que se corram todos os dados obtidos, e à medida que se vai correndo os dados, vai-se fazendo a diferença entre dados consecutivos e vai-se guardando o valor dessa diferença no vector g . Na linha 47, é criado outro ciclo *for* com o intuito de obter os

dados correspondentes a cada *sliding window*, ou seja, este ciclo irá definir um conjunto de 20 dados do vector g , em que a *sliding window* irá variar de um em um frame, para que na linha 51 seja calculado o valor absoluto do somatório dos dados que estão presentes na *sliding window* e gravar o resultado no vector soma.

3.5. Rede Neuronal

A rede neuronal usada neste trabalho foi gerada através da *toolbox Neural Network Start* do MATLAB, em que posteriormente foi seleccionada a *tool* de *Pattern Recognition*. Em seguida, foi seleccionada o tipo de rede de *Breast Cancer*, uma vez que para este trabalho existem apenas duas categorias de *targets*, ou seja, a mão do utilizador ou se encontra numa determinada posição ou não. Seguidamente, são seleccionadas as percentagens de dados que serão usados para o treino, validação e teste da rede. Para este trabalho foi definido que 70% dos dados seriam usados para treinar a rede, 15% para a validar e 15% para a testar. Por fim, foi seleccionada o número de *hidden neurons*, que para este rede foram 10.

Depois de definida a rede seleccionam-se os seus *inputs* e os seus *outputs*. Para a realização deste trabalho, os *inputs* da rede será a *feature* resultante dos sinais EMG do utilizador proveniente de cada eléctrodo do dispositivo de captação de dados e os *outputs* serão os três tipos de movimentos presentes em cada gesto.

Foram ainda definidos padrões de treino, de modo a aumentar a eficiência da rede neuronal. Definiu-se que o número máximo de iterações seria de 100 iterações, o número máximo de aumentos de validação seria de 200 e a magnitude de gradiente teria um mínimo de $1e^{-8}$.

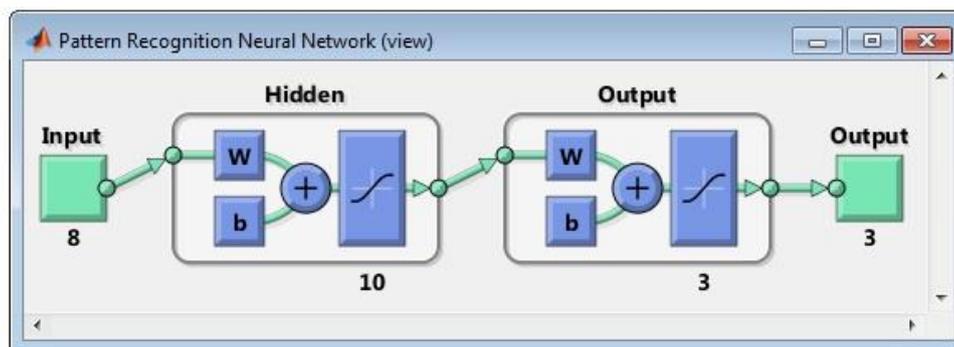


Figura 3.11. Representação da rede neuronal utilizada

4. PROCEDIMENTO E RESULTADOS OBTIDOS

Este capítulo tem o objectivo de descrever, detalhadamente, todo o trabalho realizado para o desenvolvimento desta dissertação de tese

A metodologia adoptada é dividida em quatro tipos de sub-rotinas: (i) sub-rotinas associadas à captação de sinais musculares, (ii) sub-rotinas associadas ao processamento dos sinais captados; (iii) sub-rotinas associadas ao reconhecimento do gesto correspondente aos dados captados. Para a captação de dados foi usado o dispositivo *Myo Gesture Control* produzido pela *Thalmic Labs*, enquanto que o desenvolvimento das outras sub-rotinas foi feito em *Matlab* usando o *software* comercial *Matlab 2013a*.

Foram captados sinais de cinco movimentos diferentes: (i) indicador, (ii) punho, (iii) dedos, (iv) pronação do pulso, (v) flexão palmar. Estes movimentos foram seleccionados do artigo “*Learning System for Myoelectric Prosthetic Hand Control by Forearm Amputees*” (Haruhisa Kawasaki, et al., 2014), porém podem ser escolhidos quaisquer tipo de gestos para se fazer o reconhecimento através de sinais musculares.

O algoritmo do reconhecimento de gestos através de sinais musculares está representado na figura 4.1.

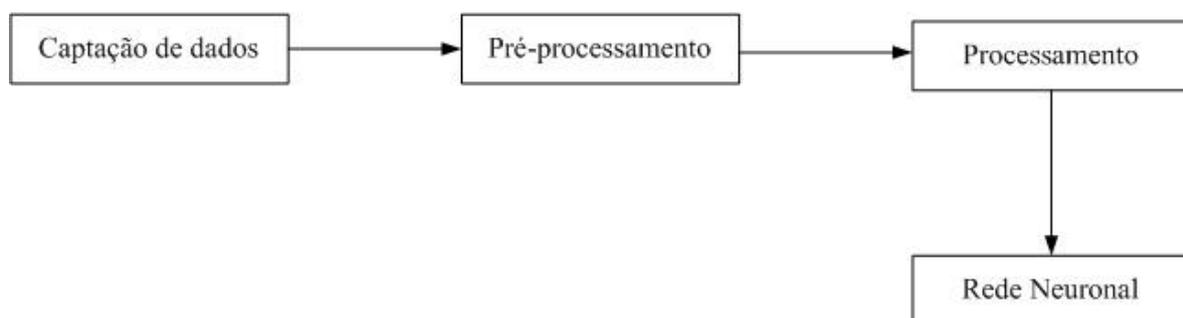


Figura 4.1. Algoritmo do sistema.

Como se pode ver na figura, existem quatro estágios principais. O primeiro, designado por *Captação de dados*, é dedicado à leitura e captação dos sinais EMG provenientes do utilizador ao realizar um determinado movimento.

O segundo estágio é designado por *Pré-Processamento*, e consiste em dividir cada tipo de gesto em três etapas: (i) posição inicial; (ii) início do movimento; (iii) fim do movimento, de modo a que, através desta divisão, se consiga gerar a matriz alvo para cada tipo de movimento. Por fim, ir-se-á aplicar um *low-pass filter* aos dados capturados, de modo a poder-se remover o ruído do sinal captado para que se consiga uma melhor eficiência no reconhecimento do gesto.

O terceiro estágio tem o nome de *Processamento*, e é aqui que será calculado a *feature* dos sinais EMG que dará entrada na rede neuronal de forma a haver reconhecimento do tipo de gesto.

O quarto e último estágio tem a designação de *Reconhecimento*, e é neste estágio em que numa primeira fase é criada uma rede neuronal, cuja a primeira etapa é realizar um treino para que a rede neuronal consiga associar os sinais EMG ao tipo de gesto que este representa, e por fim, depois de treinada, a rede faz o reconhecimento do tipo de gesto correspondente aos sinais EMG que estão a ser analisados.

4.1. Captação dos sinais EMG

Nesta fase foram medidos e gravados os sinais EMG três vezes para cada tipo de movimento, de modo a que um conjunto de dados sirva para treinar a rede, e os outros dois para testar se a rede reconhece o movimento com dados diferentes daqueles para que foi treinada.

Os movimentos consistem em:

- **Indicador:** a mão encontra-se numa posição relaxada e dobra-se o dedo indicador o máximo possível e, em seguida, retorna-se à posição inicial;
- **Punho:** a mão encontra-se numa posição relaxada e cerra-se o punho até a mão estar completamente fechada e, em seguida, retorna-se à posição inicial;
- **Dedos:** a mão encontra-se numa posição relaxada e dobra-se o dedo médio, o dedo anelar e o dedo mindinho, em simultâneo, ao máximo. Em seguida, retorna-se à posição inicial;
- **Pronação do pulso:** a mão encontra-se numa posição relaxada e faz-se a pronação do pulso até ao limite máximo e, em seguida, retorna-se à posição inicial;
- **Flexão palmar:** a mão encontra-se numa posição relaxada e flete-se a palma da mão ao máximo e, em seguida, retorna-se à posição inicial.

De modo a que os gestos gravados sejam o mais idênticos possível entre si, cada gesto tem a duração de aproximadamente cinco segundos, a velocidade do gesto e respectiva intensidade são idênticas e todos começam com a mesma posição inicial, como nos indica a figura 4.2. A posição inicial consiste em ter o cotovelo apoiado, o antebraço ligeiramente levantado e a mão relaxada.

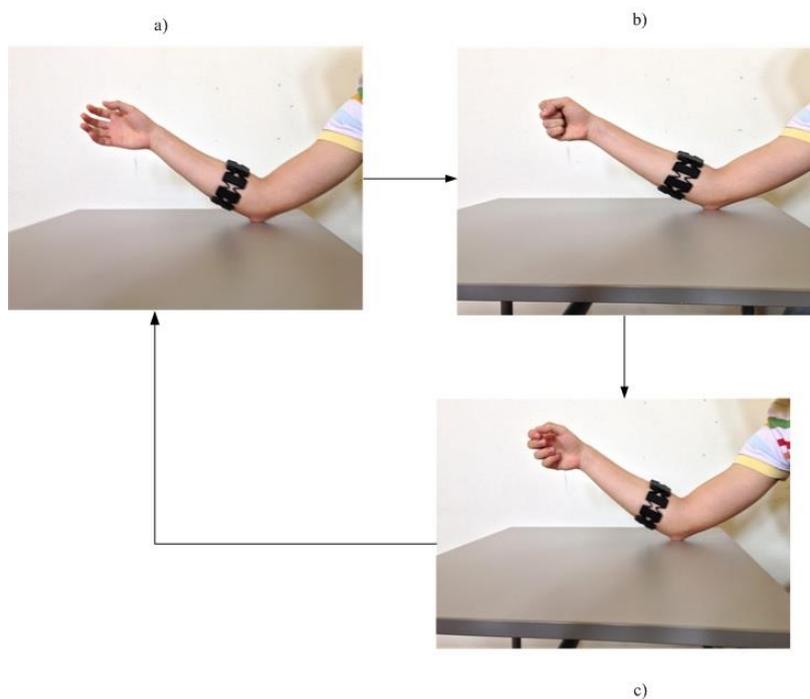


Figura 4.2. Movimentos presentes no gesto punho: a) posição inicial; b) início do movimento; c) fim do movimento.

Para cada gesto o *Myo Gesture Control* disponibiliza os sinais EMG por *frame* de cada eléctrodo numa tabela.

Tabela 4.1. Exemplo de sinais EMG do movimento dedos1.

	<i>timestamp</i>	EMG1	EMG2	EMG3	EMG4	EMG5	EMG6	EMG7	EMG8
1	1,46E+15	-1	-1	-1	-14	-27	-9	-17	1
2	1,46E+15	2	3	1	-5	25	9	13	-17
3	1,46E+15	-1	-3	2	11	16	-4	7	11
4	1,46E+15	-2	-1	1	70	22	2	-4	-1
5	1,46E+15	-4	-3	-3	-36	-25	-6	-18	-18
6	1,46E+15	5	7	7	3	-13	1	35	31
7	1,46E+15	-1	-3	-14	5	8	1	-19	-7

Desta forma, podemos representar graficamente os sinais EMG de todos os eléctrodos de um movimento, de forma a obter uma melhor visão dos resultados, tal como mostra a figura 4.3.

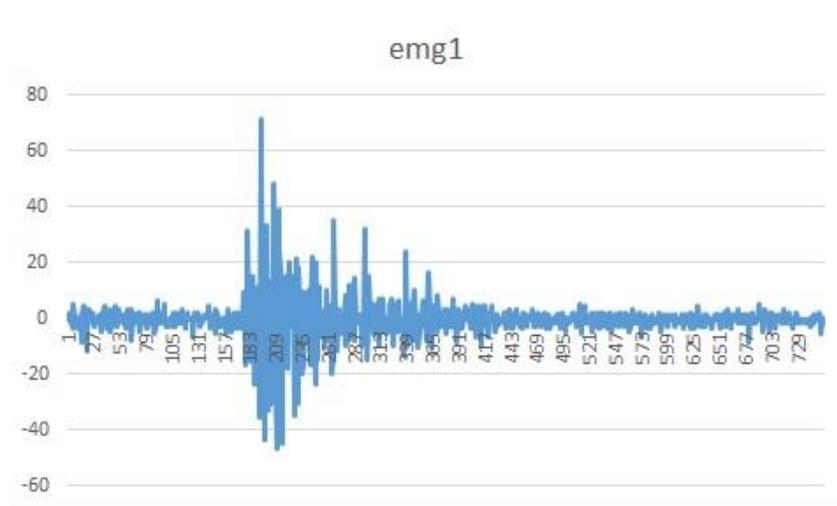


Figura 4.3. Sinais EMG do movimento dedos1 captados pelo eléctrodo1.

4.2. Pré-Processamento

Tal como foi referido anteriormente, este estágio está subdividido em duas tarefas distintas:

- divisão de cada tipo de gesto em três tipos diferentes de movimentos;
- aplicação de um *low-pass filter* aos sinais EMG captados.

4.2.1. Tipos de movimentos

Na primeira tarefa foram analisados os sinais EMG captados, através da sua visualização gráfica, como é representada na figura 4.3. Assim sendo, os gestos foram divididos, conforme estão representados na tabela 4.2.. Na imagem 4.3. pode-se observar a divisão feita para cada tipo de gesto.

Tabela 4.1. Exemplo de sinais EMG do movimento dedos1.

gesto	Posição inicial	Início do movimento	Fim do movimento
Indicador	[1;107] [299;801]	[108;211]	[212;298]
Punho	[1;470] [1012;2500]	[471;726]	[727;1011]
Dedos	[1;170] [461;755]	[171;297]	[298;460]
Pronação do pulso	[1;163] [377;789]	[164;230]	[231;376]
Flexão palmar	[1;108] [462;640]	[109;285]	[286;461]

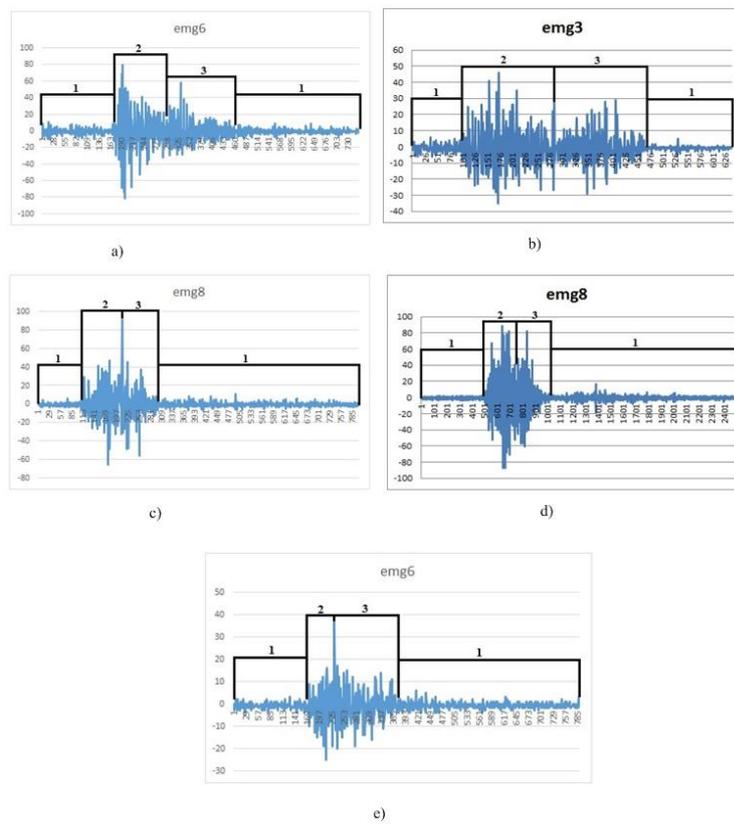


Figura 4.4. Divisão de movimentos para os vários gestos: a) dedos; b) flexão palmar; c) indicador; d) punho; e) pronação.

4.2.2. Aplicação de um *low-pass filter*

Tal como foi referido na secção 3.2, é aplicado um *low-pass filter* aos dados provenientes dos sinais EMG do utilizador.

O filtro é aplicado a cada conjunto de dados provenientes de cada eléctrodo, e é aplicado para todas as captações de sinal e para todos os gestos.

Com a utilização deste filtro obtém-se uma melhor visualização da actividade muscular presente em cada gesto, como se pode ver pela figura 4.5. Nessa figura é apresentado o resultado proveniente da utilização do filtro nos dados obtidos através da captação dos sinais EMG do utilizador, enquanto era realizado o gesto *dedos*.

A concluir, serão os dados filtrados que servirão como *inputs* para o cálculo da *feature*.

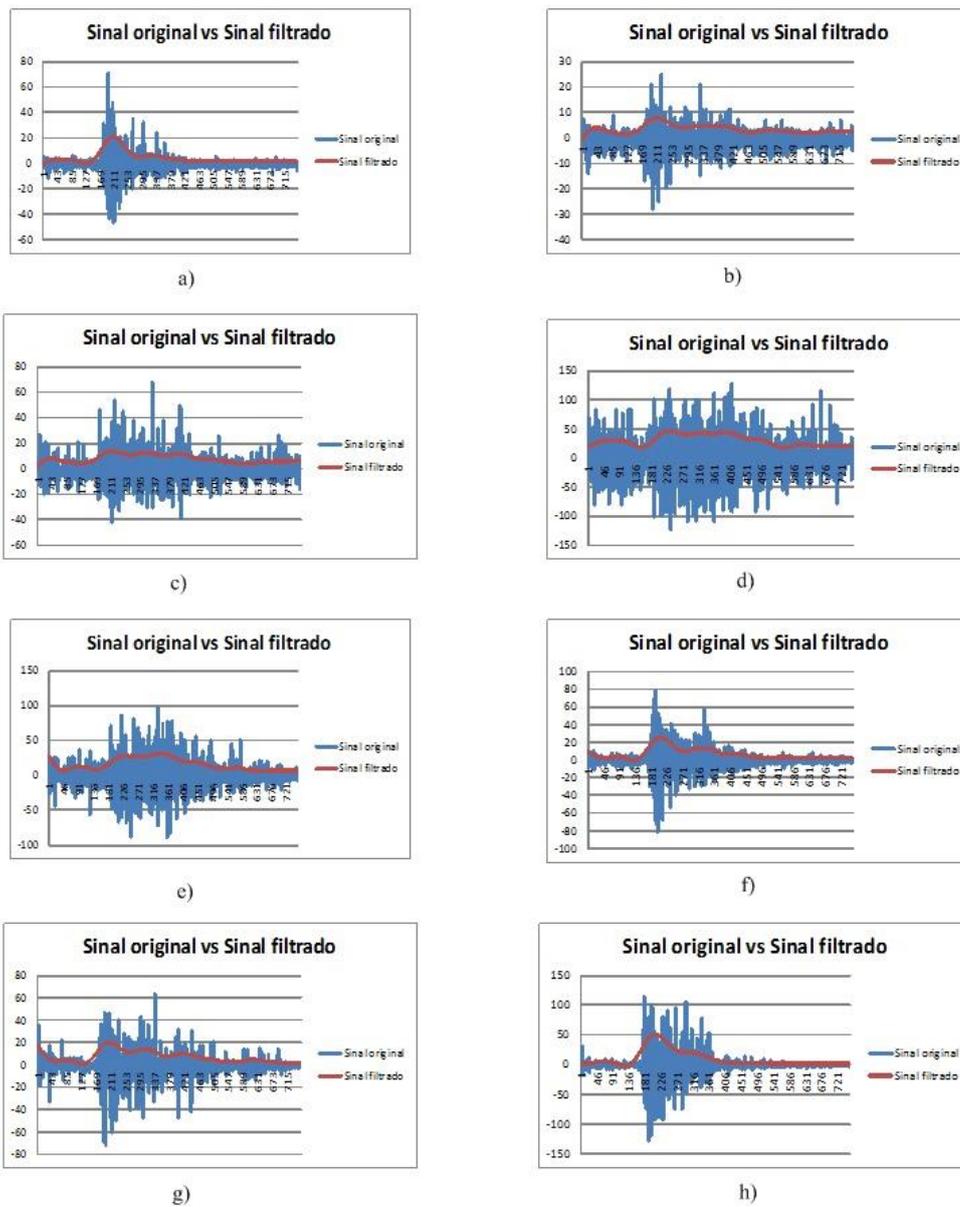


Figura 4.5. Comparação do sinal original com o mesmo sinal filtrado no movimento dedos: a) comparação para os sinais provenientes do elétrico nº1; b) comparação para os sinais provenientes do elétrico nº2; c) comparação para os sinais provenientes do elétrico nº3; d) comparação para os sinais provenientes do elétrico nº4; e) comparação para os sinais provenientes do elétrico nº5; f) comparação para os sinais provenientes do elétrico nº6; g) comparação para os sinais provenientes do elétrico nº7; h) comparação para os sinais provenientes do elétrico nº8.

4.3. Rede Neuronal

Chegado ao último estágio, é criada uma rede neuronal como foi descrito na secção 3.5. Como foi referido anteriormente, cada gesto foi gravado três vezes, uma gravação servirá para treinar a rede e as outras duas para se comparar se o *software* consegue fazer um reconhecimento com dados diferentes aos que foram usados para o treino da rede.

De seguida, são apresentados os resultados obtidos do reconhecimento de cada movimento para cada gesto. Por motivos de apresentação, os resultados estão agrupados nos cinco tipos de gestos diferentes, sendo que o primeiro resultado do reconhecimento para cada gesto diz respeito aos dados que foram usados para o treino da rede neuronal, e os restantes dois são os resultados do reconhecimento, utilizando dados que não foram usados para treinar a rede neuronal.

Para se fazer o reconhecimento do movimento, no caso do dados que foram usados para o treino da rede neuronal, foi seleccionado o *frame* que se encontra no centro do intervalo do movimento que se pretende estudar. Os intervalos dos movimentos estão representados na tabela 4.2. Para o reconhecimento dos movimentos que não foram usados no treino da rede, os *frames* foram obtidos pela visualização dos gráficos dos sinais EMG que estão representados no anexo A e posteriormente, foram seleccionados os *frames* que apresentavam melhores resultados.

Tabela 4.3. Reconhecimento dos movimentos no gesto dedos usando os dados que foram utilizados para o treino da rede neuronal.

dedos	Posição inicial	Início do movimento	Fim do movimento
Posição inicial	0.9886	0.0109	0.0482
Ínicio do movimento	0.0266	0.9986	0.0
Fim do movimento	0.0892	0.0460	0.9736
Posição inicial	0.9466	0.0264	0.0918

Como se pode verificar pela tabela 4.3. o *software* conseguiu fazer um reconhecimento correto para todos os movimentos, uma vez que a maior percentagem apresentada pelo *software* para cada gesto corresponde ao gesto que estava a ser realizado.

Tabela 4.4. Reconhecimento dos movimentos no gesto dedos2.

Frame	Dedos 2	Posição inicial	Início do movimento	Fim do movimento
50	Posição inicial	0.9924	0.0041	0.0276
240	Início do movimento	0.7721	0.3894	0.0470
270	Fim do movimento	0.0476	0.1350	0.6376
700	Posição inicial	0.9905	0.0140	0.0304

A tabela 4.4 mostra que o *software* conseguiu reconhecer correctamente o movimento *Posição inicial* e com uma boa eficiência. Contudo, apesar de conseguir

identificar também correctamente o *Fim do movimento*, a eficiência baixou. No entanto, não conseguiu identificar o *Início do movimento*.

Tabela 4.5. Reconhecimento dos movimentos no gesto dedos3.

<i>Frame</i>	Dedos 3	Posição inicial	Início do movimento	Fim do movimento
50	Posição inicial	0.9950	0.0090	0.0210
150	Início do movimento	0.9200	0.0401	0.1832
420	Fim do movimento	0.2331	0.0475	0.4677
700	Posição inicial	0.9487	0.0679	0.0271

Neste novo caso, o *software* voltou a reconhecer correctamente a *Posição inicial*, contudo não apresenta bons resultados para a identificação do *Início do movimento* e do *Fim do movimento*.

Tabela 4.6. Reconhecimento dos movimentos no gesto indicador usando os dados de treino.

indicador	Posição inicial	Início do movimento	Fim do movimento
Posição inicial	1.0000	0.0000	0.0032
Início do movimento	0.0000	0.9996	0.0017
Fim do movimento	0.0000	0.0008	1.0000
Posição inicial	1.0000	0.0001	0.0007

Como se pode verificar pela tabela 4.4. o *software* fez um reconhecimento correto para todos os movimentos, uma vez que a maior percentagem apresentada pelo *software* para cada gesto corresponde ao gesto que estava a ser realizado.

Tabela 4.7. Reconhecimento dos movimentos no gesto indicador2.

Frame	Indicador2	Posição inicial	Início do movimento	Fim do movimento
150	Posição inicial	0.9999	0.0001	0.0001
400	Início do movimento	0.0002	0.9942	0.0011
540	Fim do movimento	0.0000	0.0003	1.0000
800	Posição inicial	0.9999	0.0000	0.0019

Como se pode verificar pela tabela 4.5. o *software* voltou a fazer um reconhecimento correto para todos os movimentos, uma vez que a maior percentagem apresentada pelo *software* para cada gesto corresponde ao gesto que estava a ser realizado.

Tabela 4.8. Reconhecimento dos movimentos no gesto indicador3.

<i>Frame</i>	Indicador3	Posição inicial	Início do movimento	Fim do movimento
80	Posição inicial	1.0000	0.0000	0.0004
250	Início do movimento	0.0000	0.0002	1.0000
340	Fim do movimento	0.0000	0.9996	0.0058
700	Posição inicial	0.9996	0.0003	0.0011

Como pode ser visto na tabela 4.6, o *software* conseguiu identificar correctamente quando é que a mão se encontrava na posição inicial, porém trocou o reconhecimento do *Início do movimento* com o *Fim do movimento*, ou seja, quando a mão se encontrava a iniciar o movimento a rede neuronal indicava que a mão estava no fim do respectivo movimento e vice-versa.

Tabela 4.9. Reconhecimento dos movimentos no gesto pronação do pulso usando os dados de treino.

Pronação do pulso	Posição inicial	Início do movimento	Fim do movimento
Posição inicial	1.0000	0.0000	0.0000
Início do movimento	0.0000	0.9988	0.0003
Fim do movimento	0.0001	0.0000	1.0000
Posição inicial	0.9999	0.0000	0.0000

. Como se pode verificar pela tabela 4.7. o *software* voltou a fazer um reconhecimento correto para todos os movimentos, uma vez que a maior percentagem apresentada pelo *software* para cada gesto corresponde ao gesto que estava a ser realizado.

Tabela 4.10. Reconhecimento dos movimentos no gesto pronação do pulso 2.

Frame	Pronação do pulso 2	Posição inicial	Início do movimento	Fim do movimento
50	Posição inicial	0.9944	0.1098	0.0000
250	Início do movimento	0.0003	0.9681	0.0235
414	Fim do movimento	0.0000	0.0000	1.0000
600	Posição inicial	1.0000	0.0000	0.0000

Novamente o *software* voltou a fazer um reconhecimento correcto para todos os movimentos.

Tabela 4.11. Reconhecimento dos movimentos no gesto pronação do pulso 3.

<i>Frame</i>	Pronação do pulso 3	Posição inicial	Início do movimento	Fim do movimento
50	Posição inicial	0.9961	0.0000	0.0201
160	Início do movimento	0.0000	0.9543	0.9913
270	Fim do movimento	0.0001	0.0010	0.9704
600	Posição inicial	0.9999	0.0004	0.0000

O *software* voltou a não conseguir reconhecer correctamente todos os gestos, porém nesta situação, o *software* reconhece em ambas as situações que a mão se encontra na *Posição inicial*, reconhece também correctamente o *Fim do movimento*, mas faz um reconhecimento errado do *Início do movimento*.

Tabela 4.12. Reconhecimento dos movimentos no gesto flexão palmar com dados de treino.

Flexão palmar	Posição inicial	Início do movimento	Fim do movimento
Posição inicial	0.9992	0.0379	0.0004
Início do movimento	0.0000	1.0000	0.0119
Fim do movimento	0.0425	0.0021	0.9718
Posição inicial	0.9971	0.0101	0.0246

O *software* voltou a fazer um reconhecimento correcto para todos os movimentos.

Tabela 4.13. Reconhecimento dos movimentos no gesto flexão palmar2.

<i>Frame</i>	Flexão palmar 2	Posição inicial	Início do movimento	Fim do movimento
25	Posição inicial	0.9988	0.6832	0.0001
240	Início do movimento	0.1506	1.0000	0.0000
300	Fim do movimento	0.0000	0.6876	0.9998
500	Posição inicial	0.9961	0.0298	0.0001

Novamente o *software* voltou a fazer um reconhecimento correcto para todos os movimentos.

Tabela 4.14. Reconhecimento dos movimentos no gesto flexão palmar3.

<i>Frame</i>	Flexão palmar 3	Posição inicial	Início do movimento	Fim do movimento
25	Posição inicial	0.9983	0.0000	0.6297
200	Início do movimento	0.9208	0.9827	0.0000
390	Fim do movimento	0.0014	0.0094	0.9992
600	Posição inicial	0.9978	0.0037	0.0002

Neste caso, o *software* volta a conseguir fazer um reconhecimento correcto para todos os movimentos, porém volta a ter dificuldades a identificar o *Início do movimento*, pois apresenta uma percentagem muito próxima com a da *Posição Inicial*.

Tabela 4.15. Reconhecimento dos movimentos no gesto punho com dados de treino.

Punho	Posição inicial	Início do movimento	Fim do movimento
Posição inicial	0.9989	0.0008	0.0059
Início do movimento	0.0005	0.9989	0.0024
Fim do movimento	0.0019	0.0141	0.9812
Posição inicial	0.9990	0.0144	0.0007

Foi obtido, novamente um bom reconhecimento para todos os movimentos.

Tabela 4.16. Reconhecimento dos movimentos no gesto punho2.

Frame	Punho 2	Posição inicial	Início do movimento	Fim do movimento
400	Posição inicial	0.9924	0.0046	0.0065
1000	Início do movimento	0.0002	0.9001	0.1522
1300	Fim do movimento	0.0004	0.0561	0.9657
2200	Posição inicial	0.9912	0.0016	0.0082

Volta-se a verificar que houve um bom reconhecimento para todos os movimentos.

Tabela 4.17. Reconhecimento dos movimentos no gesto punho3.

<i>Frame</i>	Punho 3	Posição inicial	Início do movimento	Fim do movimento
250	Posição inicial	0.9859	0.0022	0.0252
550	Início do movimento	0.0574	0.9987	0.0002
725	Fim do movimento	0.0000	1.0000	0.4335
1200	Posição inicial	0.9956	0.0025	0.0052

Como se pode verificar pela tabela 4.17. o *software* faz um bom reconhecimento para todos os movimentos, excepto para o *Fim do movimento*, que neste caso identifica como *Início do movimento*, ou seja, para este caso o *software* não consegue fazer um reconhecimento do *Fim do movimento*.

5. CONCLUSÕES E TRABALHOS FUTUROS

O presente trabalho teve como objectivo principal o desenvolvimento de um *software* que consiga reconhecer gestos da mão do utilizador, através dos seus sinais EMG. O *software* foi desenvolvido com base na metodologia de dispositivos controláveis através de sinais EMG. No final deste trabalho, o *software* é capaz de fazer o reconhecimento da posição inicial, do início do movimento e o final de movimento, para qualquer gesto, porém quando são usados sinais que não foram utilizados para o treino da rede neuronal, o *software*, por vezes, tem dificuldades ou não consegue reconhecer o início do movimento e o fim do movimento. Isto acontece devido a só se ter usado uma gravação de cada gesto para se treinar a rede neuronal. Devia-se ter feito um treino com um maior número de repetições por gestos, de modo a que a rede neuronal tivesse uma base de dados maior para fazer um reconhecimento correto.

O *software* desenvolvido é composto por quatro estágios diferentes: uma fase de captação de dados, destinada a obter os sinais EMG provenientes do utilizador enquanto este realiza determinado gesto; uma fase de pré-processamento, em que primeiro os sinais de um gesto são subdivididos em três tipos de movimento, posição inicial, início do movimento, fim do movimento, e em seguida os sinais são filtrados; uma fase de processamento, em que consiste na fragmentação do sinal em *sliding window* e posteriormente o cálculo da *feature*; uma fase em que é usada uma rede neuronal, em que, em primeiro lugar existe uma criação de uma rede neuronal e seu respectivo treino de um gesto à escolha, e finalmente faz-se o reconhecimento, que consiste em usar a rede para determinar que tipo de movimento está presente em determinado *frame*.

Após a análise dos resultados obtidos foi possível concluir que houve um treino insuficiente, uma vez que estão presentes situações em que o *software* não conseguiu reconhecer correctamente o tipo de movimento que estava presente. Isso deveu-se a vários factores, tais como:

- ter sido impossível gravar os gestos todos exactamente com a mesma duração, velocidade e intensidade;

- terem sido gravadas poucas repetições de cada gesto, uma vez que foi só utilizada uma gravação para o treino da rede neuronal;
- a rede neuronal não foi treinada o suficiente, dever-se-ia ter usado mais repetições de cada gesto para o treino da rede, de modo a que a rede tivesse mais informação disponível.

Deste modo o objectivo inicialmente proposto para este trabalho foi atingido, apesar de não ter sido com a melhor eficiência. Assim, sugerem-se alguns trabalhos futuros para melhorar este *software*:

- Desenvolver um processo de captação de dados, que garanta uma duração e velocidade de gestos constante;
- Desenvolver uma base de dados que possua informação suficiente para que haja um treino correcto e capaz da rede neuronal;
- Desenvolver um método que consiga resolver o problema do reconhecimento nas partes em que acontece transição de movimentos;
- Realizar uma versão deste *software* que consiga funcionar em tempo real.

REFERÊNCIAS BIBLIOGRÁFICAS

- Riillo, F., Quitadamo, L. R., Cavrini, F., Gruppioni (2014). “Optimization of EMG-based hand gesture recognition: Supervised vs. unsupervised data preprocessing on healthy subjects and transradial amputees”. *Biomedical Signal Processing and Control*, 14(1), 117–125. <http://doi.org/10.1016/j.bspc.2014.07.007>
- Chi, C. F., Shih, Y. C., & Chen, W. L. (2012). “Effect of cold immersion on grip force, EMG, and thermal discomfort”. *International Journal of Industrial Ergonomics*, 42(1), 113–121. <http://doi.org/10.1016/j.ergon.2011.08.008>
- Barros, G. De. (n.d.). “O que é Eletromiografia ?”, <http://www.cpaqv.org/mtpmh/eletromiografia.pdf>, 05-09-2016
- Al-Angari, H. M., Kanitz, G., Tarantino, S., & Cipriani, C. (2016). “Distance and mutual information methods for EMG feature and channel subset selection for classification of hand movements. *Biomedical Signal Processing and Control*”, 27, 24–31. <http://doi.org/10.1016/j.bspc.2016.01.011>
- Carpi, F., Rossi, D. De, & Menon, C. (2006). “Non invasive brain-machine interfaces”. *ESA Ariadna Study*, 31(0). Retrieved from <http://www.esa.int/gsp/ACT/doc/ARI/ARI>
- Chi, C. F., Shih, Y. C., & Chen, W. L. (2012). “Effect of cold immersion on grip force, EMG, and thermal discomfort”. *International Journal of Industrial Ergonomics*, 42(1), 113–121. <http://doi.org/10.1016/j.ergon.2011.08.008>
- Control, K. J. K. E. (2014). “EMG-Based Control of a Robot Arm Using Low-Dimensional Embeddings”. The MIT Faculty has made this article openly available . Please share how this access benefits you . Your story matters . Citation Institute of Electrical and Electronics Engineers / IEEE .
- De Luca, C. J., Adam, A., Wotiz, R., Gilmore, L. D., & Nawab, S. H. (2006). “Decomposition of surface EMG signals”. *J Neurophysiol*, 96(3), 1646–1657. <http://doi.org/10.1152/jn.00009.2006>.This
- Englehart, K., Hudgins, B., Parker, P. A., & Stevenson, M. (1999). “Classification of the Myoelectric Signal using Time-Frequency Based Representations”. *Medical Eng. & Physics*, 21, 431–438.
- Kawasaki, H., Kayukawa, M., Sakaeda, H., & Mouri, T. (2014). “Learning system for myoelectric prosthetic hand control by forearm amputees”. *Proceedings - IEEE International Workshop on Robot and Human Interactive Communication, 2014–Octob*(October), 899–904. <http://doi.org/10.1109/ROMAN.2014.6926367>

- Liu, J., Zhang, D., Sheng, X., & Zhu, X. (2014). “Quantification and solutions of arm movements effect on sEMG pattern recognition”. *Biomedical Signal Processing and Control*, 13(1), 189–197. <http://doi.org/10.1016/j.bspc.2014.05.001>
- Pan, L., Zhang, D., Liu, J., Sheng, X., & Zhu, X. (2014). “Continuous estimation of finger joint angles under different static wrist motions from surface EMG signals”. *Biomedical Signal Processing and Control*, 14, 265–271. <http://doi.org/10.1016/j.bspc.2014.08.004>
- Terrell, T., & Powner, E. (1990). “Introduction to digital filters. *Digital Signal Processing: Principle*”s, ..., (1), 261–276. Retrieved from <http://books.google.com/books?hl=en&lr=&id=8qjgCKbYltcC&oi=fnd&pg=PA78&dq=Introduction+to+Digital+Filters&ots=o2GAqVEssx&sig=kL6rDdhoUkQ6T7rXoE5d0ZFu4oQ>, 05-09-2016
- Yang, C., Liang, P., Li, Z., Ajoudani, A., Su, C., & Bicchi, A. (2015). “Teaching by Demonstration on Dual-arm Robot using Variable Stiffness Transferring”, 1202–1208.
- Young, S. S. (1975). “Signal filtering. *Electronics and Power*”, 21(1), 53. <http://doi.org/10.1049/ep.1975.0060>, 05-09-2016
- Zhang, F., Li, P., Hou, Z. G., Lu, Z., Chen, Y., Li, Q., & Tan, M. (2012). “SEMG-based continuous estimation of joint angles of human legs by using BP neural network”. *Neurocomputing*, 78(1), 139–148. <http://doi.org/10.1016/j.neucom.2011.05.033>

ANEXO A

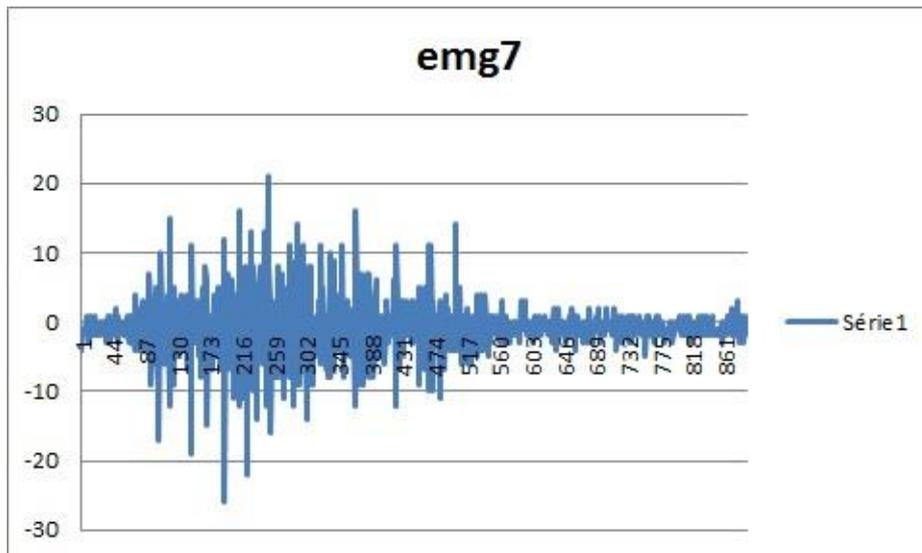


Figura A1. Gráfico dos sinais EMG do eléctrodo 7 no gesto dedos2.

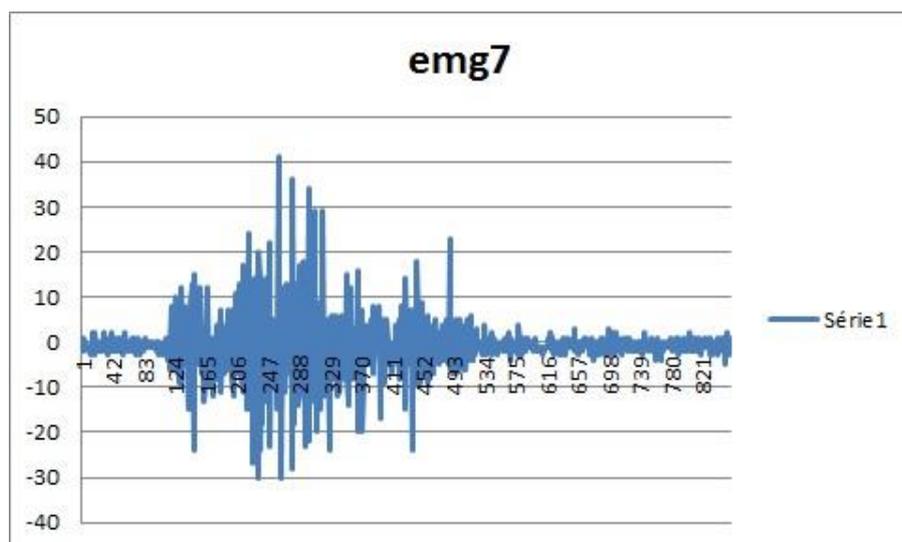


Figura A2. Gráfico dos sinais EMG do eléctrodo 7 no gesto dedos3.

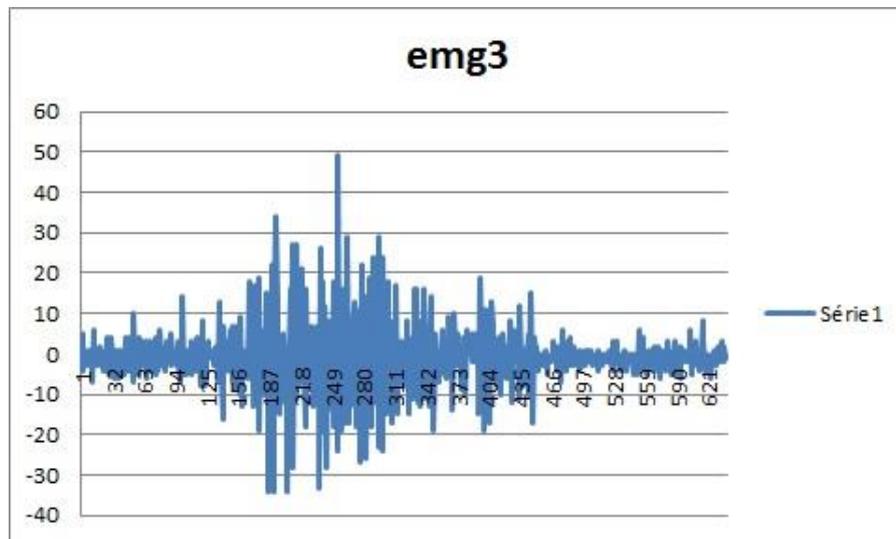


Figura A3. Gráfico dos sinais EMG do eléctrodo 3 no gesto flexão palmar 2.

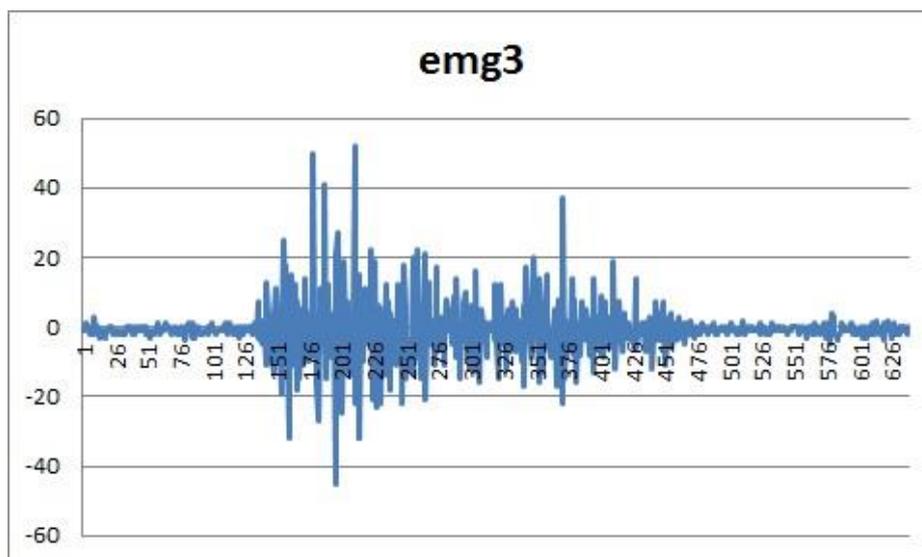


Figura A4. Gráfico dos sinais EMG do eléctrodo 3 no gesto flexão palmar 3.

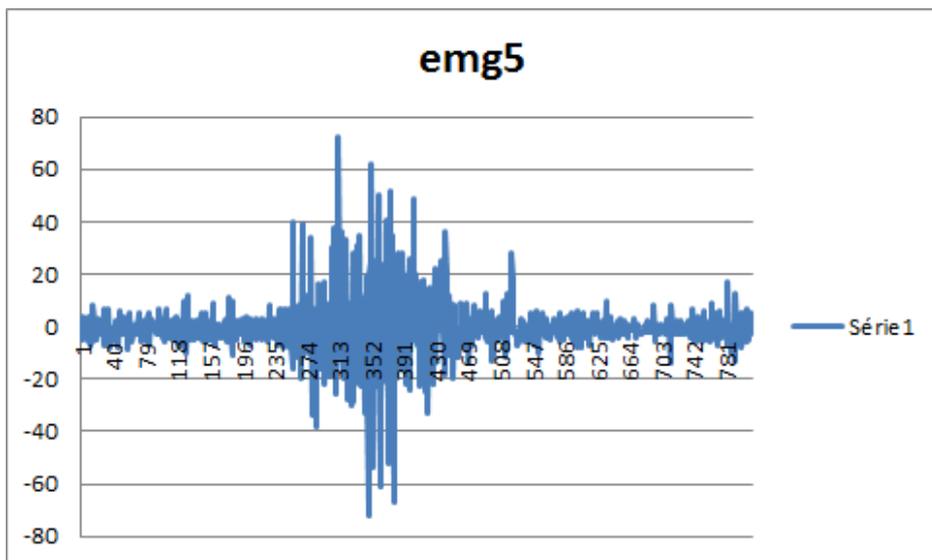


Figura A5. Gráfico dos sinais EMG do eléctrodo 5 no gesto pronação do pulso 2.

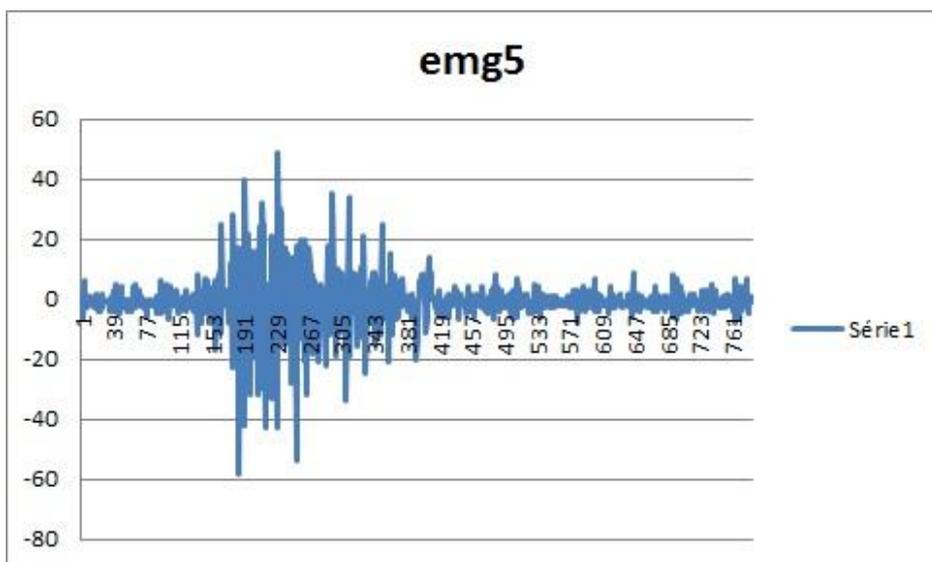


Figura A6. Gráfico dos sinais EMG do eléctrodo 5 no gesto pronação do pulso 3.

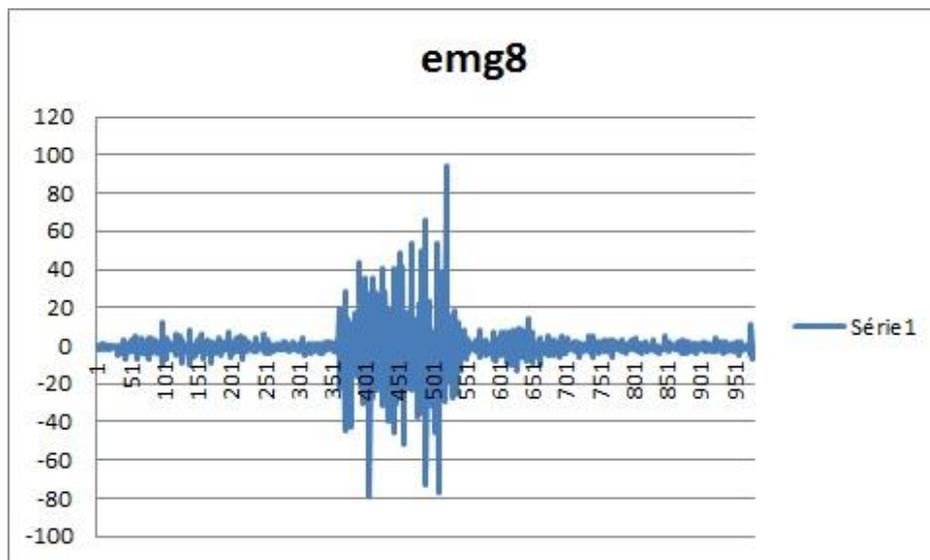


Figura A7. Gráfico dos sinais EMG do eléctrodo 8 no gesto indicador 2.

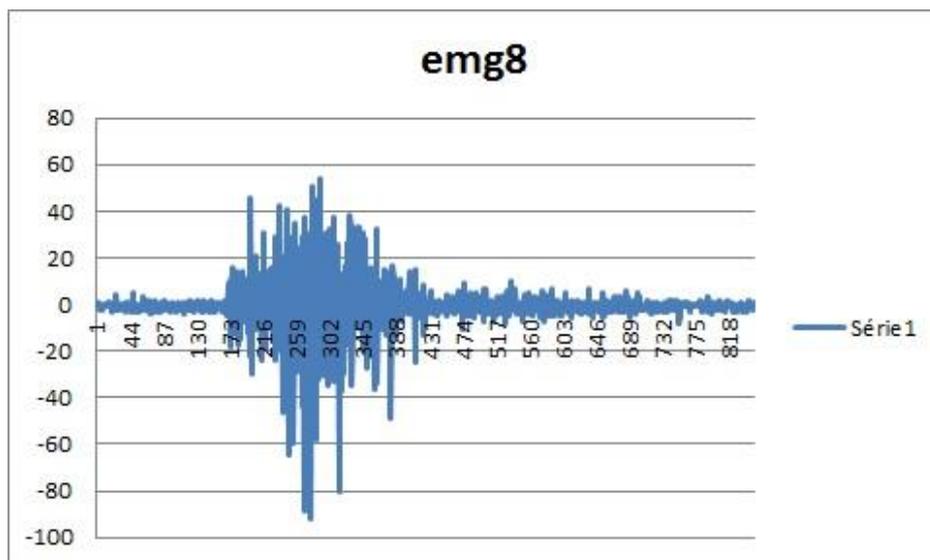


Figura A8. Gráfico dos sinais EMG do eléctrodo 8 no gesto indicador 3.

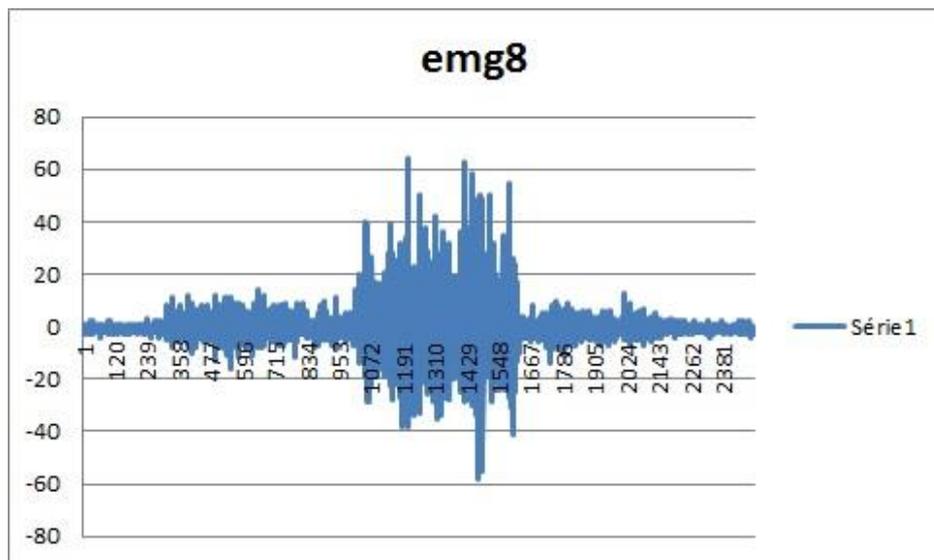


Figura A9. Gráfico dos sinais EMG do eléctrodo 8 no gesto punho 2.

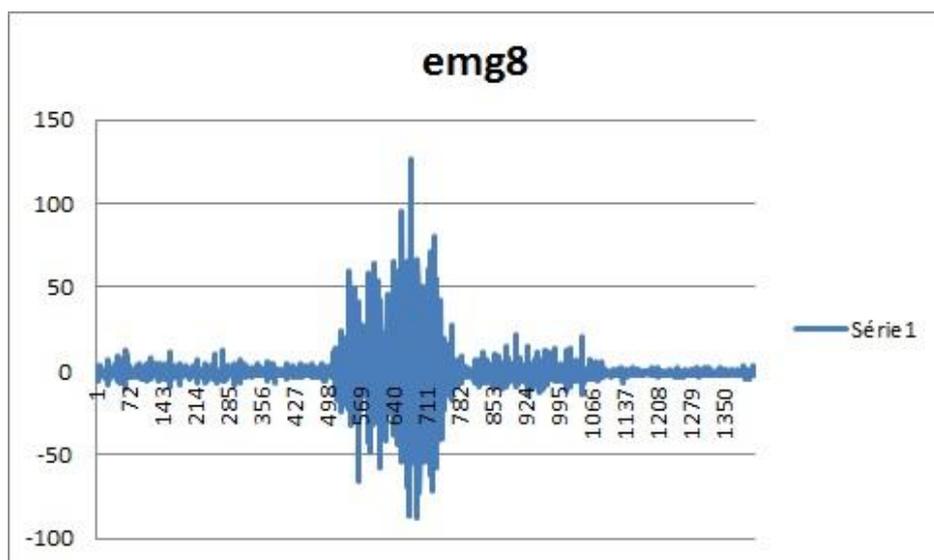


Figura A10. Gráfico dos sinais EMG do eléctrodo 8 no gesto punho 3.

Erro! A origem da referência não foi encontrada.
