



CATARINA CANHOTO CONSOLADO

Licenciatura em Ciências de Engenharia Biomédica

**DESENVOLVIMENTO DE UMA INTERFACE
HOMEM-COMPUTADOR PARA A
IDENTIFICAÇÃO EM TEMPO REAL E
INTELIGENTE DE CONTRAÇÕES
VOLUNTÁRIAS NO SINAL
ELETROMIOGRÁFICO APLICADO A PESSOAS
COM DOENÇAS NEURODEGENERATIVAS**

MESTRADO EM ENGENHARIA BIOMÉDICA

Universidade NOVA de Lisboa
Dezembro, 2024



DESENVOLVIMENTO DE UMA INTERFACE HOMEM-COMPUTADOR PARA A IDENTIFICAÇÃO EM TEMPO REAL E INTELIGENTE DE CONTRAÇÕES VOLUNTÁRIAS NO SINAL ELETROMIOGRÁFICO APLICADO A PESSOAS COM DOENÇAS NEURODEGENERATIVAS

CATARINA CANHOTO CONSOLADO

Licenciatura em Ciências de Engenharia Biomédica

Orientadora: Doutora Ana Rita Mendes Londral Gamboa

Professora Auxiliar, Faculdade de Ciências e Tecnologia da Universidade NOVA de Lisboa

Coorientadora: Doutora Cláudia Regina Pereira Quaresma

Professora Auxiliar, Faculdade de Ciências e Tecnologia da Universidade NOVA de Lisboa

Júri

Presidente: Doutora Célia Maria Reis Henriques

Professora Associada, Faculdade de Ciências e Tecnologia da Universidade NOVA de Lisboa

Arguente: Doutor Gabriel Pereira Pires

Professor Adjunto, Escola Superior de Tecnologia de Tomar do Instituto Politécnico de Tomar

Orientadora: Doutora Ana Rita Mendes Londral Gamboa

Professora Auxiliar, Faculdade de Ciências e Tecnologia da Universidade NOVA de Lisboa

Desenvolvimento de uma Interface Homem-Computador para a Identificação em Tempo Real e Inteligente de Contrações Voluntárias no Sinal Eletromiográfico aplicado a Pessoas com Doenças Neurodegenerativas

Copyright © Catarina Canhoto Consolado, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

AGRADECIMENTOS

Nesta secção gostaria de expressar os meus agradecimentos a todas as pessoas que me apoiaram ao longo do meu percurso académico, em especial durante a etapa de realização da dissertação.

Em primeiro lugar, gostaria de expressar o meu profundo agradecimento à minha orientadora, Professora Ana Rita Londral, que confiou e acreditou em mim, esteve sempre presente para me auxiliar e, sobretudo, teve sempre uma palavra de apoio durante todos os obstáculos com que me defrontei. De igual modo, à minha coorientadora, Professora Cláudia Quaresma, por toda a disponibilidade que sempre demonstrou para me ajudar bem como pela confiança e apoio prestados durante todas as etapas do trabalho.

Adicionalmente, quero agradecer a toda a equipa do Value for Health COLAB, que me acolheram, ajudaram e com os quais foi um prazer partilhar os meus dias de trabalho. Expressar também o meu agradecimento à empresa PLUX Wireless Biosignals que me cedeu o equipamento necessário para a realização da dissertação.

Gostaria de expressar a minha sincera gratidão a toda a equipa da Associação Portuguesa de Esclerose Lateral Amiotrófica (APELA), sobretudo às Terapeutas da Fala Marta Pinto e Cláudia Melo, que desde o primeiro dia se mostraram disponíveis para participar no desenvolvimento deste trabalho. Esta ajuda e colaboração foram cruciais para o sucesso da presente dissertação! Deixar também um obrigado a todos os voluntários, tanto da APELA como colegas, que participaram sem hesitação no estudo e permitiram que realizasse todos os testes necessários.

A todos os meus amigos, um enorme obrigado pelo companheirismo, entretida e momentos de diversão que passámos durante estes anos. Sem eles esta experiência não teria sido a mesma!

O agradecimento mais especial vai para a minha família, para os quais um obrigado será sempre pouco para todo o apoio e companhia que me proporcionaram ao longo destes 5 anos.

Por último, mas sem dúvida, não menos importante, ao meu namorado Miguel resta-me agradecer-lhe pelo apoio incansável durante os bons e maus momentos. Obrigada por teres sido o meu pilar durante estes anos.

RESUMO

As tecnologias de apoio à comunicação são essenciais para mitigar a incapacidade de comunicar resultante de disfunções neuromotoras em doenças neurodegenerativas, como a Esclerose Lateral Amiotrófica (ELA). As alterações motoras progressivas dificultam a utilização de produtos de apoio já desenvolvidos, como os sistemas de *eyetracking*. Por conseguinte, o controlo de uma interface através da deteção de atividade muscular voluntária, com sinais de Eletromiografia (EMG), surge como uma solução promissora para evitar, por exemplo, a necessidade de movimentos complexos e controlados. Esta dissertação descreve as etapas iniciais de uma aplicação inteligente capaz de detetar contrações musculares em tempo real e convertê-las em comandos de controlo do computador.

Primeiramente, foi desenvolvida a interface para aquisição, visualização e classificação em tempo real do sinal de eletromiografia para a deteção de contrações voluntárias, através da implementação de um modelo de *Deep Learning* (DL), combinando uma Rede Neuronal Convolutiva e uma *Long-short Term Memory*. Para o controlo do computador, foi criado um algoritmo para detetar padrões nas previsões do modelo, permitindo dois comandos distintos: Clique Curto (CC) e Clique Longo (CL). O sistema foi validado através da realização de testes em 31 participantes saudáveis e em 16 participantes com ELA.

Durante a fase de teste do modelo com sinais semelhantes aos de tempo real, obteve-se uma *accuracy* de 92,3%, 90,5% nos testes em indivíduos saudáveis e 81,1% nos indivíduos com patologia. A análise comparativa dos eventos realizados e detetados revelou uma sensibilidade de 91,9% para os CCs no grupo saudável e 59,1% no grupo com ELA. Para os CLs, obteve-se 75,3% e 39,3% em indivíduos sem e com patologia, respetivamente.

O trabalho desta dissertação contribui com um modelo DL, uma base de dados de sinais EMG de pessoas com ELA e um protótipo funcional de uma interface inteligente que permite acionar dois comandos distintos. Como trabalho futuro sugere-se o desenvolvimento de modelos específicos para a ELA e que se adaptem à evolução da doença.

Palavras-chave: Tecnologia de Apoio à Comunicação, Aprendizagem Automática, Deteção de contração muscular, Interface Homem-Computador, Esclerose Lateral Amiotrófica

ABSTRACT

Communication assistive technologies are essential to mitigate the inability to communicate resulting from neuromotor dysfunctions in neurodegenerative diseases such as Amyotrophic Lateral Sclerosis (ALS). Progressive motor impairments make it difficult to use existing support products, such as eyetracking systems. Therefore, controlling an interface through the detection of voluntary muscle activity using electromyographic signals emerges as a promising solution to avoid, for example, the need for complex, controlled movements. This dissertation describes the initial stages of an intelligent application capable of detecting muscle contractions in real time and converting them into computer control commands.

Firstly, an interface was developed for the real-time acquisition, visualisation and classification of the Electromyography (EMG) signal to detect voluntary contractions, through the implementation of a Deep Learning (DL) model, combining a Convolutional Neural Network and a Long-short Term Memory. To control the computer, an algorithm was created to detect patterns in the model's predictions, enabling two different commands: Short Click (SC) and Long Click (LC). The system was validated by testing it on 31 healthy participants and 16 participants with ALS.

During the testing phase, using signals similar to those in real time, an accuracy of 92.3% was obtained, 90.5% in the tests on healthy individuals and 81.1% in those with pathology. The comparative analysis of realised and detected events revealed a recall of 91.9% for SCs in the healthy group and 59.1% in the group with pathology. For the LCs, 75.3% was obtained in individuals without pathology and 39.3% in those with pathology, respectively.

This dissertation contributes with a DL model, a database of EMG signals from people with ALS and a functional prototype of an intelligent interface that allows two different commands to be activated. Future work may include the development of specific models for ALS that adapt to the evolution of the disease.

Keywords: Communication Assistive Technologies, Machine Learning, Detection of muscle onset, Human-Computer Interface, Amyotrophic Lateral Sclerosis

ÍNDICE

Índice de Figuras	viii
Índice de Tabelas	x
Abreviaturas	xi
1 Introdução	1
1.1 Contextualização e Motivação	1
1.2 Objetivos e Contribuições	2
1.3 Estrutura da Dissertação	3
2 Fundamentos Teóricos	4
2.1 Esclerose Lateral Amiotrófica	4
2.2 Tecnologias de Apoio	5
2.2.1 Caracterização das Tecnologias de Apoio	6
2.2.2 Tecnologias de Apoio à Comunicação	6
2.3 Eletromiografia	7
2.4 Aprendizagem Automática	8
2.4.1 <i>Deep Learning</i>	8
2.4.2 Desempenho do Algoritmo	10
2.4.3 <i>Human-in-the-loop Machine Learning</i>	10
3 Estado de Arte	11
3.1 Algoritmos e Métodos de Detecção de Contrações Musculares	11
3.2 Algoritmos de <i>Deep Learning</i> para Detecção de Padrões	13
3.3 Desafios Atuais dos Algoritmos de Detecção de Contrações Musculares	15
4 Materiais e Métodos	16
4.1 <i>Design Science Research</i> e <i>User Centered Design</i>	16

4.2	Desenvolvimento de uma Aplicação para Detecção <i>Online</i> e Inteligente de Contrações Voluntárias no sinal EMG	16
4.2.1	Primeira Iteração - Protótipo Inicial de Interface Gráfica	17
4.2.2	Algoritmo de <i>Deep Learning</i>	18
4.2.3	Algoritmo de Classificação de Padrões de Ativação Muscular	21
4.2.4	Segunda Iteração - Protótipo Inteligente da Aplicação com Controle de uma Apresentação <i>PowerPoint</i>	23
4.2.5	Terceira Iteração - Protótipo Inteligente da Aplicação com Controle de um Vídeo na Aplicação <i>Youtube</i>	24
5	Resultados e Discussão	26
5.1	Primeira Iteração - Protótipo Inicial da Interface Gráfica	26
5.2	Algoritmo de <i>Deep Learning</i>	26
5.2.1	Constituição da Base de Dados de Sinais Eletromiográficos	26
5.2.2	Sessão <i>Offline</i> de Treino	27
5.3	Algoritmo de Classificação de Padrões de Ativação Muscular	29
5.4	Segunda Iteração - Protótipo Inteligente da Aplicação com Controle de uma Apresentação <i>Power-Point</i>	29
5.5	Terceira Iteração - Protótipo Inteligente da Aplicação com Controle de um Vídeo na Aplicação <i>Youtube</i>	30
5.5.1	Análise em Qualidade, Amplitude e Frequência dos sinais EMG	30
5.5.2	Análise do Desempenho <i>Offline</i> do modelo	33
5.5.3	Análise do Desempenho em Tempo Real do Sistema desenvolvido	34
5.5.4	Resumo e Discussão Final dos Resultados	38
6	Conclusão e Trabalho Futuro	39
	Bibliografia	41
	Apêndices	
A	Informação Complementar à Metodologia	47
A.1	Métricas de Avaliação	48
A.2	Sessão de Teste da Segunda Iteração	48
A.3	Sessão de Teste da Terceira Iteração	49
B	Resultados Complementares	51
B.1	Página Principal e de Visualização do sinal EMG desenvolvidas na Primeira Iteração	52
B.2	Algoritmo de <i>Deep Learning</i>	53
B.2.1	Análise da Proporção de Dados para cada Classe com a Variação do Tamanho da Janela e Percentagem de <i>Overlap</i>	53
B.2.2	Descrição dos Modelos Desenvolvidos e os Resultados obtidos	54

B.3	Análise em Frequência, Amplitude e Qualidade dos sinais EMG adquiridos durante os Testes da Terceira Iteração	55
B.4	Algoritmo de Detecção de Padrões de Ativação Muscular	63
B.4.1	Gráficos de Barra com Agregação e Descrição dos Resultados da Detecção em Tempo Real	63
B.4.2	Exemplos de Sinais EMG com Detecção de Falsos Negativos	64
 Anexos		
I	Trabalho Complementar	65

ÍNDICE DE FIGURAS

2.1	Quadro de Comunicação Dinâmico. À esquerda quadro inicial com os temas de cada quadro de comunicação específico e à direita quadro referente ao tema "Sentimentos". Imagem retirada de [4].	7
3.1	Deteção de atividade muscular através do critério de <i>threshold</i> único. a) Sinal EMG estável e sem distúrbios. b) Sinal EMG de paciente com doença neuromuscular. c) Sinal EMG com presença de atividade rítmica como tremores. Imagem retirada de [7].	12
4.1	Esquema que descreve a Característica da Base de Dados utilizada para o Treino e Teste do modelo de <i>Deep Learning</i>	20
4.2	Esquema Ilustrativo do Funcionamento do Algoritmo de Deteção de Padrões de Ativação Muscular para o Clique Curto.	22
5.1	Exemplo de um Sinal EMG eliminado durante o processo de <i>Labelling</i> (à esquerda) e de um Sinal EMG <i>labelled</i> utilizando a aplicação <i>Upalgo Labeling</i> (à direita).	27
5.2	Matriz de Confusão para a classificação de janelas em três classes, Rest (R), One_Click (OC) e Transition (T). À esquerda a divisão em janelas foi realizado com dimensão de 150 ms e à direita com 300 ms ambos com <i>overlap</i> de 30%.	27
5.3	Matrizes de Confusão com os resultados da implementação da segunda metodologia de <i>labelling</i> na base de dados (à esquerda) e com o teste do modelo em sinais adquiridos com a MuscleBAN (à direita).	28
5.4	Sinais EMG adquiridos no participante H_V (à esquerda) e H_GG (à direita).	30
5.5	Variação da SNR (dB) (à esquerda) e Amplitude Máxima (mV) (à direita) para o grupo de participantes saudáveis.	31
5.6	Sinais EMG adquiridos no participante H_Z (à esquerda) e H_HH (à direita)	32
5.7	Variação da SNR (dB) (à esquerda) e Amplitude Máxima (mV) (à direita) para o grupo de participantes com ELA.	32

5.8	Variação da RMS para o grupo sem patologia (à direita) e com patologia (à esquerda).	32
5.9	Sinais EMG adquiridos no participante H_NN (à esquerda) e ALS_OO (à direita).	33
5.10	Espectro de densidade espectral de potência para o sinal EMG adquirido no participante H_NN (à esquerda) e ALS_OO (à direita).	33
5.11	Matriz de Confusão para a classificação <i>offline</i> dos sinais adquiridos na Terceira Iteração para o grupo de participantes saudáveis (à esquerda) e com ELA (à direita).	33
5.12	Exemplos de FN na detecção das intenções de movimento. À esquerda é ilustrado um CC não detetado, a imagem central mostra um CC detetado como CL e à direita CC/CL identificados durante o repouso.	35
5.13	Exemplo de CLs detetados como CCs no participante H_GG.	35
5.14	Sinais EMG dos participantes ALS_VV (à esquerda) e ALS_A2 (à direita).	36
5.15	Sinal EMG do participante ALS_SS com identificação dos CCs detetados.	37
5.16	Sinal EMG do participante ALS_TT com identificação dos CCs detetados.	37
B.1	Página Principal da Aplicação	52
B.2	Página de aquisição do sinal EMG com a detecção de ativação muscular por <i>threshold</i> . A figura da esquerda diz respeito à aplicação com a implementação de visualização de ambos os sinais, em bruto e processado, sendo que a da direita apresenta apenas o gráfico do sinal EMG processado.	52
B.3	Comparação do desempenho do Algoritmo de Classificação de Padrões de Ativação Muscular entre a Tarefa 1 e 2 no conjunto de 21 participantes saudáveis para os quais se verificaram falhas na detecção.	63
B.4	Comparação do desempenho do Algoritmo de Classificação de Padrões de Ativação Muscular entre a Tarefa 1 e 2 no conjunto de 13 participantes com ELA para os quais se verificaram falhas na detecção.	64
B.5	Exemplos de sinais de 4 participantes saudáveis para os quais ocorreram Falsos Negativos identificados.	64

ÍNDICE DE TABELAS

5.1	Comparação entre o Tempo médio de decisão/intenção-decisão dos Cliques Curto e Longo para o grupo de participantes saudáveis e com ELA.	38
A.1	Informação Demográfica dos participantes saudáveis da Sessão de Teste em Tempo Real da Segunda Iteração do Protótipo Inteligente da Aplicação. . . .	48
A.2	Informação Demográfica dos participantes saudáveis da Sessão de Teste em Tempo Real da Terceira Iteração do Protótipo Inteligente da Aplicação. . . .	49
A.3	Informação Demográfica dos participantes com ELA da Sessão de Teste em Tempo Real da Terceira Iteração do Protótipo Inteligente da Aplicação. . . .	50
B.1	Proporção (%) entre a quantidade de janelas classificadas como <i>Rest</i> , <i>One_Click</i> e <i>Transition</i> , considerando diferentes valores de dimensão de janela e sobreposição	53
B.2	Descrição das características das diferentes camadas constituintes dos modelos de <i>Deep Learning</i> desenvolvidos	54
B.3	Resultados obtidos no conjunto de teste para os diferentes modelos	54
B.4	Descrição em frequência, amplitude e qualidade dos sinais EMG adquiridos em participantes saudáveis. Na coluna "Músculo", "FUC"denomina Flexor Ulnar do Carpo e "M"denomina Masséter. As linhas destacadas correspondem a sinais que foram descartados para o estudo devido a problemas durante a aquisição.	55
B.5	Descrição em frequência, amplitude e qualidade dos sinais EMG adquiridos em participantes com ELA. Na coluna "Músculo", "FUC"denomina Flexor Ulnar do Carpo, "M"denomina Masséter e "Q"corresponde a Quadríceps. A linha destacada corresponde a um sinal que foi descartado para o estudo devido a problemas durante a aquisição.	61

ABREVIATURAS

APELA	Associação Portuguesa de Esclerose Lateral Amiotrófica (pp. 2, 16, 17, 25, 26, 30, 39)
CC	Clique Curto (pp. 21–25, 29, 34–40)
CL	Clique Longo (pp. 21–25, 29, 30, 34–39)
CNN	Rede Neuronal Convolutacional, do termo em inglês <i>Convolutional Neural Network</i> (pp. 9, 13, 14, 21)
DH	Doença de Huntington (p. 4)
DL	<i>Deep Learning</i> (pp. 3, 4, 8, 9, 12, 15, 17–19, 21, 22, 26, 29, 34, 35, 38–40, 51)
DNs	Doenças Neurodegenerativas (p. 4)
DP	Doença de Parkinson (p. 4)
DSR	<i>Design Science Research</i> (p. 16)
ELA	Esclerose Lateral Amiotrófica (pp. 1–5, 7, 8, 11, 16–19, 23–26, 30–34, 37–40)
EMG	Eletromiografia (pp. 1–4, 8–15, 17, 18, 20, 22–26, 28, 30–32, 34, 35, 38–40, 51)
FN	Falsos Negativos (pp. 10, 23, 35–37, 48)
FP	Falsos Positivos (pp. 10, 48)
FUC	Flexor Ulnar do Carpo (pp. 24, 30, 31, 34–37)
HITL-ML	<i>Human-in-the-loop Machine Learning</i> (pp. 10, 40)
LSTM	<i>Long-short Term Memory</i> (pp. 9, 13, 14, 21)
M	Masséter (pp. 24, 30–32)
ML	<i>Machine Learning</i> (pp. 8, 10–12)
NMI	Neurónios Motores Inferiores (p. 5)

NMS	Neurónios Motores Superiores (p. 5)
OC	<i>One_click</i> (pp. 19, 20, 22, 34)
PA	Potencial de Ação (pp. 7, 8)
R	<i>Rest</i> (pp. 19, 20, 22, 34)
RMS	Raiz Quadrática Média, do termo em inglês <i>Root Mean Square</i> (pp. 25, 32)
RNN	Rede Neuronal Recorrente, do termo em inglês <i>Recurrent Neural Network</i> (p. 9)
SNR	Relação Sinal-Ruído, do termo em inglês <i>Signal-to-Noise Ratio</i> (pp. 12, 13, 25, 31, 36–38)
T	<i>Transition</i> (pp. 20, 27)
TA	Tecnologia de Apoio (pp. 2, 5, 6, 26)
UCD	<i>User-Centered Design</i> (p. 16)
UM	Unidade Motora (p. 7)
VN	Verdadeiros Negativos (pp. 10, 48)
VP	Verdadeiros Positivos (pp. 10, 23, 36, 37, 48)

INTRODUÇÃO

O trabalho de investigação descrito nesta dissertação foi realizado de acordo com as normas estabelecidas no código de ética da Universidade Nova de Lisboa. O trabalho descrito e o material apresentado nesta dissertação, com as exceções claramente indicadas, constituem trabalho original realizado pela autora.

1.1 Contextualização e Motivação

Atualmente, existe um conjunto de doenças neurodegenerativas que se manifestam por alterações na função motora e, conseqüentemente, pela perda de capacidade de realizar atividades da vida diária como comunicar, comer, caminhar e escrever [2]. Exemplos dessas doenças são a Esclerose Lateral Amiotrófica (ELA), doença de Parkinson (DP) e doença de Huntington (DH) [3].

Devido às limitações que estas doenças provocam e pela falta de cura inerente, há por parte dos cuidadores e dos próprios doentes uma grande preocupação em garantir que estes conseguem manter a sua autonomia, tomar decisões e interagir com o ambiente que os rodeia o máximo de tempo possível.

Neste sentido, as tecnologias de apoio são dispositivos ou sistemas criados para superar limitações que impedem a realização de uma determinada tarefa que é significativa para a pessoa ou para proporcionar maior facilidade e segurança na sua execução [4]. Na ELA, como referido, a maioria dos doentes perdem a capacidade de se expressar por meio da fala e por isso, têm sido desenvolvidas tecnologias de apoio à comunicação com base no seguimento do movimento ocular ou na atividade cerebral, de modo a dar resposta a pessoas em fases mais avançadas da doença onde a capacidade motora já é mais reduzida. Contudo, são reportadas dificuldades ao nível do processo de adaptação que se demonstra bastante dependente de cuidadores e de equipas especializadas [5]. Adicionalmente, embora os sistemas de controlo pelo olhar apresentem um bom funcionamento, possuem limitações para algumas pessoas devido a latência no movimento. Como tal, a utilização de Eletromiografia (EMG) para a deteção de movimentos voluntários e conseqüentemente para o controlo de interfaces de comunicação tem sido explorado com o objetivo de

umentar a qualidade de vida das pessoas, permitindo o uso das tecnologias de apoio e garantir que o sistema se mantém funcional durante as várias fases de progressão da doença [6]. No entanto, os métodos mais utilizados para a deteção de atividade muscular são baseados na definição de um *threshold* e têm-se demonstrado pouco precisos para realizar a deteção automática das intenções de movimento. Este facto deve-se às alterações de características nos sinais, resultantes da progressão da ELA, bem como à própria diminuição de atividade muscular que conduzem a que a definição de um limiar origine deteções imprecisas [7]. Além disso, à medida que a doença progride, é necessário ajustar o valor definido com frequência, tornando o uso de um dispositivo baseado neste princípio desmotivante.

Assim, apesar dos avanços tecnológicos dos dispositivos atuais, é fundamental desenvolver interfaces inteligentes e adaptáveis, que assegurem a aplicabilidade das tecnologias a todas as pessoas com doenças neurodegenerativas, pelo máximo de tempo possível, mesmo quando as suas capacidades motoras estão gravemente afetadas. A Inteligência Artificial tem-se mostrado um caminho viável para desenvolver soluções com estes requisitos. No âmbito da deteção de movimentos voluntários por EMG, verifica-se um aumento na utilização de modelos de Aprendizagem Automática, capazes de identificar padrões em séries temporais e de avaliar os sinais de forma precisa, adaptando-se às suas variações características [8]. Através da sua aplicação no contexto das Tecnologia de Apoio (TA)s e teste em cenários reais, é possível criar interfaces eficazes e apelativas para os utilizadores, evitando o seu abandono precoce e preservando a sua capacidade de comunicação.

1.2 Objetivos e Contribuições

O objetivo da dissertação foi desenvolver uma interface inteligente para aplicação no contexto das tecnologias de apoio à comunicação que permitisse substituir os métodos tradicionais de classificação da ocorrência de momentos de ativação, resultando numa deteção mais precisa das contrações. Através da implementação de modelos de Aprendizagem Automática desenvolveu-se as etapas iniciais de uma aplicação que, futuramente, pode evoluir para um sistema adaptativo face às diversas alterações no EMG, características da progressão da ELA e, por vezes, de sinais de fadiga, sem que haja uma diminuição do seu desempenho. A presente dissertação foi desenvolvida em parceria com a PLUX Wireless Biosignals, Value for Health COLAB (VOH COLAB) e a Associação Portuguesa de Esclerose Lateral Amiotrófica (APELA). Para atingir o objetivo foram definidas um conjunto de atividades, nomeadamente:

1. Desenvolver uma aplicação que permita a aquisição e visualização em tempo real do sinal EMG;
2. Gerar um modelo inteligente que realize em tempo real a classificação de janelas do sinal EMG;

3. Converter as intenções de movimento em comandos de controlo do computador, para a aplicação de testes de utilização em um grupo de controlo (sujeitos sem patologia com mais de 18 anos) em contexto laboratorial;
4. Após a aplicação em contexto laboratorial, testar a utilização do sistema numa amostra de indivíduos com ELA, de modo a compreender a viabilidade do sistema e da realização de movimentos distintos para o acesso aos sistemas de comunicação;
5. Por fim, comparar os resultados obtidos em ambos os grupos, identificar os pontos a melhorar para uma versão futura do protótipo e observar se o treino de modelos com sinais saudáveis é viável para a deteção em sinais patológicos.

A presente dissertação tem como contributos, um protótipo funcional de uma interface homem-computador com aquisição de sinal EMG de superfície utilizando um dispositivo com comunicação Bluetooth, uma base de dados com sinais EMG adquiridos em participantes com e sem patologia associada, devidamente etiquetados, e a implementação em tempo real de um modelo de *Deep Learning* (DL) cuja estrutura permite que seja escalável para outras formas de deteção mais robustas e sofisticadas. Adicionalmente, foi estudada a viabilidade em participantes com ELA da realização de dois movimentos distintos para o controlo de computador. O trabalho realizado ao longo da dissertação foi selecionado, conforme o resumo submetido em Anexo I, para Apresentação Oral no 1º Fórum de Inovação em Medicina e Engenharia Biomédica, promovido pela Sociedade de Ciências Médicas de Lisboa, onde recebeu o Prémio "Sociedade de Ciências Médicas de Lisboa" pela melhor Comunicação Oral na Mesa 1 – Inteligência Artificial na Tomada de Decisões.

1.3 Estrutura da Dissertação

O documento está dividido em 6 Capítulos. No Capítulo 1 é introduzida a dissertação, onde se apresenta a motivação e os principais objetivos. No Capítulo 2 são discutidos os conceitos teóricos fundamentais para uma compreensão adequada do trabalho realizado. No Capítulo 3 é feita uma revisão de literatura sobre os métodos de deteção de contrações musculares bem como de algoritmos de DL utilizados para a deteção de padrões em diferentes sinais. O Capítulo 4 apresenta a metodologia desenvolvida e aplicada para se atingir os objetivos propostos. O Capítulo 5 contém os resultados obtidos ao longo do projeto bem como a sua discussão crítica. Por fim, o Capítulo 6 conclui a dissertação demonstrando as principais conclusões, incluindo as suas limitações e sugestões de trabalho futuro.

FUNDAMENTOS TEÓRICOS

O capítulo está estruturado em quatro Secções distintas mas que se complementam. A primeira diz respeito ao estudo da etiologia e sintomatologia da ELA, uma doença neurodegenerativa, visto que a compreensão deste tópico é essencial para o enquadramento e desenvolvimento do presente trabalho. A segunda explora as Tecnologias de Apoio, com especial foco nas que são utilizadas como suporte para a comunicação, visto ser uma das perdas causadas pelo avanço da ELA. A terceira secção descreve os biosinais, nomeadamente, o sinal eletromiográfico que será utilizado para o acesso às tecnologias de apoio para a comunicação. Por fim, na última secção é realizado um estudo dos métodos de Aprendizagem Automática, com uma descrição mais pormenorizada de modelos de DL utilizados para classificação em sinais EMG, bem como de métodos de interação Homem-Computador.

2.1 Esclerose Lateral Amiotrófica

Os neurónios são a base do funcionamento do cérebro humano, possuindo um papel fundamental na enervação dos músculos. A sua redução gradual com o envelhecimento indica que estas estruturas do sistema nervoso central são mortais e que podem sofrer alterações na sua estrutura e funções, denominada de neurodegeneração. As Doenças Neurodegenerativas (DNs) mais comuns são a doença de Alzheimer, Doença de Parkinson (DP), ELA e Doença de Huntington (DH) [3, 9]. Nesta dissertação, o estudo de caso envolverá participantes com ELA e, por isso, será abordada esta patologia detalhadamente. Contudo, tanto a DP como a DH causam sintomas motores que tornam as pessoas portadoras elegíveis para a aplicação de tecnologias como a que se encontra em estudo [10, 11].

A Esclerose Lateral Amiotrófica é a doença mais comum de degeneração dos neurónios motores [12]. Michael A van Es et al. [13] descrevem que 50% dos pacientes com ELA apresentam défice cognitivo/comportamental e cerca de 13% desenvolvem demência fronto-temporal, o que corrobora a sua classificação como doença neurodegenerativa e não apenas neuromuscular. A degeneração dos neurónios motores resultante de alterações

nas células gliais juntamente com uma resposta neuroinflamatória é apontada como a principal causa do aparecimento dos primeiros sintomas da doença [12].

Os Neurónios Motores Superiores (NMS) têm origem no córtex motor primário, onde os sinais excitatórios e inibitórios são integrados e traduzidos num sinal que controla o movimento voluntário. Os seus axónios descem até ao corno anterior da medula espinal, formando o trato corticoespinal lateral [14]. Existe ainda o trato corticoespinal anterior que está envolvido no controlo motor axial e proximal dos membros [15].

Segundo Burke, 1981 e Pierrot Deseiligny & Burke, 2005 citado por Mamede de Carvalho [16] os tratos corticoespinais juntamente com diversos tratos polissinápticos são responsáveis pelo controlo dos Neurónios Motores Inferiores (NMI). Estes neurónios transmitem sinais dos NMS para os músculos efetores, sendo categorizados em somáticos, viscerais eferentes especiais e gerais [14].

Os neurónios motores somáticos dividem-se em alfa, beta e gama [14]. De acordo com a referência de [16] a Burke (1981), os neurónios alfa são reconhecidos como os efetores finais e a sua disposição na medula varia conforme os músculos que inervam.

A ELA manifesta-se por um aparecimento focal, mas pode progredir tanto localmente como para regiões adjacentes do corpo, sendo de difícil diagnóstico e que só surge 10 a 16 meses após o início dos sintomas [13, 17]. Os fenótipos são caracterizados pela predominância de sintomas associados aos NMS ou aos NMI e pela associação às regiões neurológicas afetadas [18, 19]. A sua identificação precoce é crucial devido às diversas evoluções e prognósticos que apresentam.

As pessoas com ELA podem apresentar sintomas decorrentes dos NMI, como perda de força, diminuição do tônus muscular em músculos voluntários, atrofia e fasciculações. A degeneração dos NMS resulta em reflexos exagerados, um aumento do tônus muscular e uma diminuição da velocidade de execução dos movimentos. Outras manifestações comuns são a disartria (dificuldade na fala), disfagia (dificuldade na deglutição) e dispneia (dificuldade respiratória) [18]. Contudo, surgem frequentemente sintomas não motores como dor, distúrbios psicológicos, entre outros. A evolução da sintomatologia e resultante incapacidade pode ser avaliada através da *ALS Functional Rating Scale-Revised* (ALSFRS-R) com uma pontuação máxima de 48 [20]. Apesar de ser uma doença incurável, os sintomas são geríveis através de fármacos e apoio multidisciplinar, embora os resultados de sobrevivência sejam ainda limitados [21].

Giancarlo Logroscino et al. [22] citado por Benôit Marin et al. [23], constatou uma maior prevalência no desenvolvimento da ELA com o avanço da idade, atingindo um pico de incidência entre os 65 e 75 anos. No entanto, regista-se um aumento logo a partir dos 50/60 anos.

2.2 Tecnologias de Apoio

Em [4] é citado que de acordo com a "Assistive Technology Act for 2004", PL 108-364, uma TA é "qualquer dispositivo, equipamento ou sistema - adquirido comercialmente, modificado

ou personalizado - utilizado para aumentar, manter ou melhorar as capacidades funcionais de um indivíduo com deficiência". Segundo Cook & Polgar (2008) citado em [4] não existem duas aplicações iguais de TAs, pois as necessidades e limitações de cada utilizador são únicas e o contexto em que a tecnologia é aplicada diferem.

2.2.1 Caracterização das Tecnologias de Apoio

Cook & Polgar (2008) referenciado por [4], descreve que a caracterização das TAs pode ser feita tendo em conta o seu propósito de utilização em TA à Mobilidade, Manipulação, Orientação, Cognição ou Comunicação. As TAs à mobilidade fornecem mobilidade à pessoa, se possível autónoma, em todos os contextos físicos. A TA à Manipulação é utilizada para interagir e controlar o meio que os rodeia, enquanto as TAs à Orientação através de GPS, permitem fornecer informações acerca da localização espacial e temporal. Por fim, uma TA à Cognição oferece suporte às necessidades de pessoas que já possuem outras limitações, por exemplo a nível motor ou cognitivo [4]. Dado que o foco da dissertação é o desenvolvimento de algoritmos complementares a uma TA à comunicação, este tópico será explorado na Secção 2.2.2.

2.2.2 Tecnologias de Apoio à Comunicação

A Comunicação, segundo o projeto HEART, citado em [4], permite a interação entre as pessoas e está assente na capacidade de perceber, receber ou produzir mensagens e gerar ou verbalizar respostas. As doenças neurodegenerativas geralmente incapacitam as pessoas de comunicar e, por isso, a utilização destas tecnologias é recomendada.

2.2.2.1 Comunicação Aumentativa e Alternativa

A Comunicação Aumentativa e Alternativa desenvolve soluções para necessidades complexas de comunicação, complementando outros meios como a fala e gestos, através de métodos, modos e estratégias distintas. Este tipo de comunicação utiliza símbolos e produtos de apoio para transmitir ou receber mensagens, além de implementar técnicas para otimizar a transmissão de mensagens [4].

Os quadros de comunicação são uma dessas soluções, sendo produtos de apoio, eletrónicos ou não, que permitem à pessoa formar mensagens usando símbolos. Existem quadros dinâmicos, com submenus (como exemplificado na Figura 2.1) e estáticos [4]. Apesar das suas vantagens, é possível utilizar teclados convencionais em interfaces para a criação de mensagens por pessoas com mobilidade reduzida.

2.2.2.2 Interface pessoa/produto de apoio

A informação entre a pessoa e o dispositivo é trocada de forma bidirecional, em que o utilizador aciona o dispositivo através de uma interface de controlo que produz uma resposta visual, auditiva ou tátil [4].




Figura 2.1: Quadro de Comunicação Dinâmico. À esquerda quadro inicial com os temas de cada quadro de comunicação específico e à direita quadro referente ao tema "Sentimentos". Imagem retirada de [4].

A interface de controlo pressupõe um dispositivo de controlo utilizado para aceder ao computador e um método de seleção, que se refere ao modo como o utilizador escolhe de entre as várias opções. Este pode ser direto, se todas estiverem disponíveis, ou indireto, se forem necessários vários passos até à seleção final. A forma mais utilizada de seleção indireta é através de varrimento devido à exigência de uma capacidade motora reduzida, sendo acessível a qualquer utilizador com movimentos controlados. Nesta implementação, um conjunto de opções são destacadas de forma progressiva e com um ritmo constante, de forma visual ou auditiva, e o utilizador gera um sinal de controlo para a seleção [4].

Cook & Polgar (2008), citado em [4], descrevem que a escolha dos dispositivos de apoio deve ter em conta as dimensões, o modo de ativação e o retorno da informação após a ativação. Como método de acionamento começaram a utilizar-se sinais eletrofisiológicos porque para doentes com ELA, por exemplo, pode ser impossível utilizar botões ou realizar outros movimentos complexos, o que impossibilitaria a utilização destes dispositivos de apoio.

2.3 Eletromiografia

Os biosinais são sinais medidos no corpo humano que descrevem fenómenos fisiológicos e podem ser detetados visualmente ou através de sensores [24]. A eletromiografia é um exemplo de um biosinal e os algoritmos que foram desenvolvidos no âmbito da dissertação utilizam-na para detetar contrações voluntárias.

O sinal eletromiográfico é um sinal elétrico que resulta da corrente elétrica que é gerada quando ocorrem contrações musculares. Este sinal propaga-se ao longo do tecido muscular excitável e forma um Potencial de Ação (PA) [25, 26]. Sendo o músculo composto por inúmeras fibras musculares, a combinação da propagação dos PAs numa única Unidade Motora (UM) forma o potencial de ação da unidade motora [25]. O sinal obtido na eletromiografia de superfície pode resultar da ativação de uma única UM ou de todas as que forem recrutadas. Por sua vez, uma UM é composta pelos neurónios motores alfa, os seus axónios e as fibras musculares que inervam, sendo que quando ocorre um movimento toda a unidade motora é excitada [26].

A eletromiografia de superfície possibilita a deteção do efeito de todos os PAs gerados nos músculos que alteram a tensão na pele da zona em estudo [25]. Através desta, é possível aceder a informações para o diagnóstico e avaliação da ELA, permitindo detetar o nível de ativação muscular, a presença de fasciculações, fibrilações e ondas com formas mais pronunciadas [18, 27].

2.4 Aprendizagem Automática

A Aprendizagem Automática (adiante designada por ML, do inglês *Machine Learning*) permite que, através de modelos matemáticos, os sistemas façam previsões e tomem decisões com base num conjunto de dados, dos quais aprendem e melhoram o seu desempenho. Estes sistemas conseguem extrair padrões e informações complexas dos dados, um fator determinante para o aumento da aplicabilidade destes algoritmos em diversos setores [28]. Para o desenvolvimento de um modelo de *Machine Learning* (ML), podem ser seguidas duas abordagens possíveis: *Feature engineering*, onde as *features* (propriedades que transmitem relações entre dados e permitem a identificação de padrões [29]) são extraídas manualmente, e *Feature learning*, que implica a aplicação de DL, um subcampo de ML abordado na Secção 2.4.1 [30].

O conjunto de etapas típicas para a construção do modelo passam pelo pré-processamento do sinal que envolve a remoção de influências externas nos sinais de EMG, como artefactos de contacto, ruído dos equipamentos e instabilidade do sinal devido à sua natureza aleatória [25]. Para além dos filtros dos equipamentos, aplicam-se filtros digitais, como um passa-banda (20-500Hz) e um filtro *notch* (50/60Hz). Tendo como foco obter a amplitude do sinal, utiliza-se a função da raiz quadrada média ou o valor absoluto médio para obter o sinal retificado [27]. Posteriormente, para obter o envelope do sinal é aplicado um filtro de média móvel em janelas [27], seguido da extração de *features* temporais, estatísticas ou espectrais que melhor caracterizem o sinal [27]. Para evitar problemas com escalas distintas nos dados de entrada, aplica-se um escalonamento min-max ou normalização [31]. Finalmente, escolhe-se um conjunto de modelos para a classificação, com base no tipo de aprendizagem e no objetivo pretendido [29].

2.4.1 *Deep Learning*

O DL baseia-se na estrutura do cérebro humano para a criação de algoritmos robustos com elevada escalabilidade e versatilidade [31], denominados de redes neuronais artificiais que apresentam resultados bastante satisfatórios [32]. As redes neuronais correspondem ao algoritmo base desta abordagem de ML e são constituídas por unidades estruturais, os neurónios, que se conectam entre si para formar a rede. O conceito de *deep* surge pelo facto de os dados serem processados ao longo das diferentes camadas durante a etapa de aprendizagem. Além disso, a extração de *features* é realizada de forma automática, contra-riamente ao que acontece nos restantes modelos, o que torna o treino das redes menos

dependente do ser humano e mais eficiente, diminuindo o tempo necessário para o seu desenvolvimento [29]. No contexto da presente dissertação, destacam-se para problemas de classificação em séries temporais a combinação de Rede Neuronal Convolutiva, do termo em inglês *Convolutional Neural Network* (CNN), com *Long-short Term Memory* (LSTM) [33, 34].

A CNN é um algoritmo que se baseia em redes neuronais multicamadas. As primeiras são constituídas por camadas convolucionais, responsáveis por detetar características da camada anterior, e camadas *pooling*, que permitem a fusão de características semelhantes numa só [35]. Nesse sentido, embora estes algoritmos demonstrem grande aplicabilidade em imagem, devido à sua capacidade de extrair *features* têm sido bastante utilizados como fase inicial para constituir a informação de entrada para um segundo algoritmo [34].

Uma Rede Neuronal Recorrente, do termo em inglês *Recurrent Neural Network* (RNN), é uma tipologia de algoritmo de DL cujo principal objetivo é aprender dependências a longo termo, sendo que processa um elemento da sequência de entrada de cada vez, mas mantém a informação de todos os valores anteriores nas camadas ocultas. Contudo, durante a fase de treino surge o problema de *vanishing gradient*, uma vez que o gradiente tendencialmente aumenta ou diminui bastante devido ao algoritmo de retropropagação, o que leva ao seu desaparecimento comprometendo o processo de aprendizagem do algoritmo. Desta forma, as RNN apresentam problemas quando existe a necessidade de guardar informação por longos períodos de tempo [32, 36]. Neste sentido surgem as LSTM que, com uma célula de memória colmatam a lacuna enunciada. Através de *gates* é feito o controlo da informação que entra e sai da célula, nomeadamente através do *Forget Gate* que determina qual da informação se mantém ou qual é "esquecida", do *Input Gate* que controla o que deve ser incluído no estado da célula e, por fim, do *Output Gate* que determina o resultado dado pela mesma [32]. Tendo em conta que os sinais EMG são séries temporais e que se pretende detetar padrões através da sua análise, as LSTM são algoritmos adequados para essa mesma finalidade.

Um dos parâmetros importantes na estrutura dos modelos de DL são as funções de ativação que, lineares ou não, controlam os resultados da rede neuronal e desempenham um papel crucial na aprendizagem de características através da aplicação de transformações não lineares. Estas possuem diferentes objetivos conforme o local em que são utilizadas na rede. Nas camadas intermédias, convertem características lineares em não lineares, permitindo a propagação dessas informações. Na camada de saída, realizam previsões, transformando a combinação final de características em resultados compreensíveis. Exemplos incluem a função sigmóide, tangente hiperbólica, *softmax* e *rectified linear unit* (ReLU) [37, 38].

A função sigmóide, utilizada nas camadas de saída, produz probabilidades entre 0 e 1, sendo usada em problemas de classificação binária, mas pode causar desvanecimento do gradiente. A tangente hiperbólica, com resultados entre -1 e 1, oferece melhor *performance* de treino ao centrar os resultados em zero, mas enfrenta o mesmo problema que a sigmóide. A função *softmax* calcula a distribuição de probabilidade de um vetor de números reais,

sendo usada em modelos multiclasse. A ReLU, eficiente computacionalmente, retifica valores de entrada menores que 0, eliminando o desvanecimento do gradiente. Embora tenha tendência a *overfit*, técnicas como *dropout* podem ser utilizadas para o evitar [37, 38].

2.4.2 Desempenho do Algoritmo

A matriz de confusão é uma forma de visualização de resultados através do qual se pode aferir o número de vezes que o algoritmo classificou de forma correta ou incorreta e como foi feita essa classificação, através da divisão em: Verdadeiros Positivos (VP) que são as amostras corretamente positivas; Verdadeiros Negativos (VN) que são as amostras corretamente negativas; Falsos Positivos (FP) que são as amostras classificadas como positivas, mas que são negativas; Falsos Negativos (FN) que são as amostras classificadas como negativas, mas que são positivas [39].

Tendo em conta estes parâmetros é possível definir um conjunto de métricas de avaliação do desempenho de modelos que passam pela *Accuracy*, Sensibilidade, Precisão, Especificidade e *F1-Score*. A *Accuracy* calcula o rácio entre os VP, os VN e as previsões totais. A **Sensibilidade** descreve qual a percentagem de instâncias, classificadas corretamente, que são de facto positivas, sendo a **Especificidade** similar mas referente à classe negativa. A **Precisão** representa o rácio entre os VP e todas as previsões classificadas como positivas. Por fim, a *F1-Score* corresponde à média harmónica entre a **Precisão** e a **Sensibilidade** [31, 39].

2.4.3 Human-in-the-loop Machine Learning

No desenvolvimento tradicional de algoritmos de ML, os modelos são criados, testados e depois disponibilizados aos utilizadores sem novas alterações, o que pode levar à falta de adaptação a mudanças no contexto e à degradação do seu desempenho. A interação contínua entre humanos e algoritmos, conhecida como *Human-in-the-loop Machine Learning* (HITL-ML), surge para melhorar os modelos e aumentar a eficiência no seu desenvolvimento [40].

Tendo em consideração quem se encontra no controlo do processo de aprendizagem é possível identificar três formas de interação humano-algoritmo: Aprendizagem Ativa, em que o sistema está no controlo e pede ao humano para realizar anotações de certos dados; Aprendizagem Automática Interativa, em que o controlo do processo de aprendizagem é compartilhado entre o sistema e o humano; Ensino de Máquina, em que a interação é baseada na transferência de conhecimento permitindo que tanto humanos quanto algoritmos ensinem modelos [40]. No contexto em estudo, aplicar estas técnicas seria crucial para garantir a longevidade dos sistemas de comunicação, pois cada algoritmo ficaria progressivamente mais personalizado para o seu utilizador, nomeadamente, para as suas alterações no sinal EMG.

ESTADO DE ARTE

Este capítulo foca-se nas metodologias de deteção de padrões em sinais eletromiográficos e outros sinais adquiridos. A primeira secção fornece uma revisão da literatura sobre métodos de deteção de contrações musculares, através da definição de limiares e modelos de ML. Na segunda secção, são apresentados estudos que aplicam algoritmos de *Deep Learning* para contextos diferentes, cuja estrutura e metodologia podem ser relevantes para o presente trabalho. Por fim, são destacadas as limitações da revisão realizada.

3.1 Algoritmos e Métodos de Deteção de Contrações Musculares

Grande parte das tecnologias de apoio à comunicação que utilizam eletromiografia como controlo, baseiam-se na identificação dos momentos de contração e relaxamento muscular. Algoritmos baseados na definição de um *Threshold*, estatísticos ou por observação visual são descritos, mas novas abordagens têm surgido devido às grandes vantagens que as técnicas de ML demonstram [8].

Londral et al. [41] descreve o desenvolvimento de uma interface controlada por EMG através de uma metodologia de controlo baseada no funcionamento de um interruptor, em que sempre que é detetada uma intenção de movimento desencadeia-se uma ação no computador. Primeiro, foi descrita uma etapa de calibração para identificar a amplitude do sinal de ruído com uma duração de 5 segundos. Posteriormente, é implementado um algoritmo de variância, pela computação da máxima verosimilhança estimada para a oscilação local do sinal dividido em janelas. Os momentos de ativação voluntária são identificados como a primeira amostra cujo valor no sinal de variância ultrapasse o *threshold* pré-definido, num intervalo de tempo de pelo menos 100 milissegundos. Esta abordagem é designada como método de *Threshold Único* [8]. O sistema foi testado em doentes com ELA apresentando bons resultados em termos de adaptação, contudo surgiram dificuldades devido aos tempos de reação prolongados. Num dos participantes como a amplitude do sinal era reduzida o algoritmo não detetou com precisão [41].

Segundo a literatura, os modelos de deteção de atividade muscular implementados com mais frequência são os baseado no *threshold*, existindo métodos com um limiar único, duplo

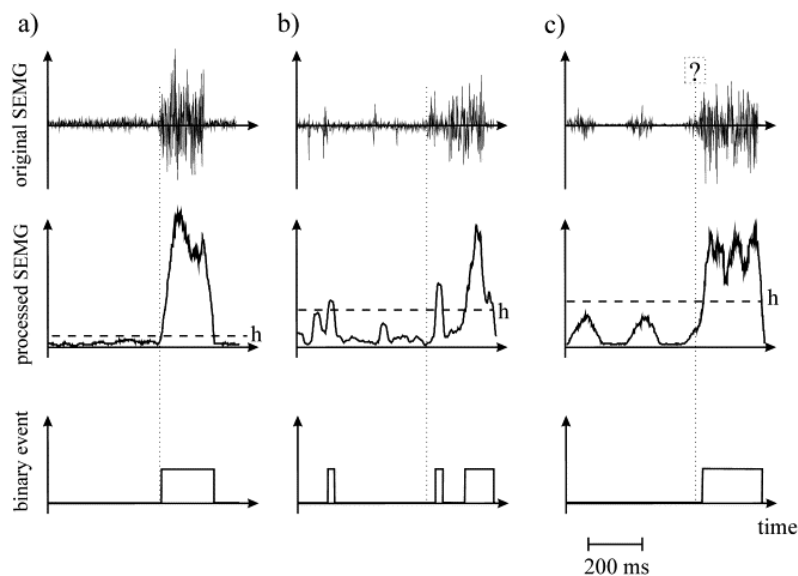


Figura 3.1: Detecção de atividade muscular através do critério de *threshold* único. a) Sinal EMG estável e sem distúrbios. b) Sinal EMG de paciente com doença neuromuscular. c) Sinal EMG com presença de atividade rítmica como tremores. Imagem retirada de [7].

ou adaptativo. Contudo, com o avanço da Inteligência Artificial e a utilização de modelos, estes demonstram as suas vantagens pela adaptabilidade e capacidade de aprendizagem das características dos sinais EMG, possibilitando a obtenção de um menor número de falsos positivos [8]. Stauder e Wolf (1999) [7] apresentaram uma análise crítica acerca da utilização de *threshold* único onde, na Figura 3.1, é observável a falta de adaptabilidade destes algoritmos a casos de sinais EMG não padronizados.

Francesco Di Nardo et al. [42] propuseram um algoritmo de DL, que permite a discriminação entre atividade eletromiográfica e ruído. O objetivo consiste num detetor de atividade muscular através de redes neuronais sendo que, para a avaliação de resultados e treino do classificador foram utilizados sinais EMG simulados com uma variedade de valores de Relação Sinal-Ruído, do termo em inglês *Signal-to-Noise Ratio* (SNR), e dois *datasets* de sinais reais. Estes pretendem mostrar a relevância desta metodologia, pela possibilidade de utilização em tempo real, em comparação com sistemas que não são baseados em ML. Foram aplicadas técnicas de pré-processamento ao sinal de EMG para obter o envelope linear, a raiz quadrada média e o escalograma do sinal (obtido através da transformada contínua da onda que oferece a distribuição de energia do sinal no domínio do tempo e frequência), que são utilizados como *input* para a previsão do modelo. Adicionalmente, foram avaliadas quatro combinações dos três parâmetros referidos através da concatenação com uma normalização min-max dos resultados. O vetor foi segmentado em janelas deslizantes com sobreposição de 10 amostras, onde cada uma foi deslocada uma amostra em relação à anterior. Cada janela foi utilizada para atribuir a *label* à amostra correspondente, dependendo do valor mais frequente. A atribuição do valor "1" significava atividade muscular e "0" a ausência de atividade, sendo que, a latência obtida foi de 3-4 milissegundos, indicada como aceitável para a utilização em tempo real.

A rede neuronal implementada foi uma "*hidden single layer (32 units) fully-connected*" com a função de ativação *Rectified Linear Unit*. De modo a obter um *output* no intervalo de 0 a 1 foi implementada a função sigmóide, contudo, os resultados binários resultam da imposição de um *threshold* de 0,5. O classificador foi treinado com uma taxa de aprendizagem de 0,001, o tamanho do *batch* de 512 para 40 *epochs* usando o algoritmo de otimização *Gradient Descent*. Os resultados obtidos demonstraram que com o aumento da relação SNR se verificou um aumento da precisão, sensibilidade e *F1-score*, embora as variações na *accuracy* sejam reportadas como baixas, demonstrando que o algoritmo teve um bom desempenho. Outro teste foi desenvolvido com o algoritmo *Support Vector Machine* em que obtiveram um erro absoluto médio superior, mas não reportaram como significativas as variações nos restantes parâmetros.

Ghislieri et al. [43] implementaram uma Rede Neuronal Recorrente, em específico uma *Long short-term memory neural network*. É descrito que estes algoritmos apresentam bons desempenhos no reconhecimento de padrões e dependência temporal num conjunto de dados. Foram simulados sinais EMG com SNR diferentes e utilizados para o treino do classificador, contudo foram feitos testes em sinais reais inclusive de pessoas com patologias a nível ortopédico e neurológico. O *dataset* foi dividido em 70% para treino, 15% para teste e 15% para validação, sendo o conjunto de validação utilizado para terminar o treino da rede quando a *accuracy* não sofrer nenhum incremento e evitar que se atinja uma situação de *overfitting*. Os modelos testados apresentam uma sequência de entrada de uma única unidade, da dimensão do sinal de EMG e um *output* com duas classes. Para o processo de treino foi utilizado o algoritmo *Adaptive Moment Estimation (ADAM)* e os sinais etiquetados utilizados para o treino do modelo foram obtidos manualmente, por observação de um especialista utilizando *MATLAB*. Posteriormente, foi implementado um método de pós-processamento em que ativações musculares com duração inferior a 30 ms não foram consideradas. O modelo final apresenta uma *accuracy* de 90% em dados reais e com um desempenho superior aos modelos com que foi comparado.

3.2 Algoritmos de Deep Learning para Detecção de Padrões

Tendo em conta que a presença de contrações musculares constitui um padrão no sinal de EMG, decidi efetuar-se uma procura por algoritmos que embora não sejam desenvolvidos com o propósito da presente dissertação, pudessem igualmente aplicar-se ao contexto em estudo.

Mohd Halim Mohd Noor et al. [34] sugerem a implementação de um modelo híbrido baseado na conjugação de uma CNN e LSTM, de modo a identificar padrões de atividade tendo como base tanto as características temporais dos dados recolhidos pelo sensor, como as relações entre as janelas de atividade. Assim, a escolha dos dois modelos mencionados é justificada pela vantagem que as CNN apresentam no reconhecimento de padrões de atividades que se repetem ao longo do tempo, enquanto as LSTM demonstram bons resultados no reconhecimento de atividades curtas e sequenciais. Os dados utilizados na

investigação passam pelo acelerómetro, segundo os três eixos, bem como o giroscópio e são recolhidos por um *smartphone* que é colocado em cada participante. As atividades em estudo perfazem um total de doze, sendo seis atividades básicas (três estáticas e três dinâmicas) e seis atividades de transição. No que diz respeito ao pré-processamento dos dados, estes são normalizados para possuírem média zero, variância unitária, segmentados em janelas de tamanho fixo sem sobreposição e etiquetadas tendo em conta a maioria de amostras que as constituem. O modelo proposto recebe como entrada um conjunto de janelas de atividades, isto é, K janelas anteriores à janela que se pretende classificar. A estrutura do modelo, responsável pela extração de *features*, é composta por camadas convolucionais, com função de ativação tangente hiperbólica (\tanh) e camadas de *pooling*. Para evitar o *overfitting* e tornar o modelo mais generalizável, é aplicada uma regularização com *dropout* após a camada de *pooling*. Esta *pipeline* é aplicada a cada janela de atividade, de modo a produzir um vetor com a concatenação das *features* extraídas de todas as janelas. O vetor corresponde à informação de entrada do denominado "módulo de aprendizagem sequencial", responsável por mapear as dependências entre janelas. O mesmo corresponde a uma rede LSTM constituída por células LSTM, cujo número depende da quantidade de *features*, visto que a célula aceita como entrada uma única característica e produz uma informação de saída, utilizada como entrada da célula seguinte. Cada uma foi definida para ter 48 unidades escondidas sendo que a rede retorna apenas o resultado da última célula. Aplicou-se novamente uma regularização com uma taxa de *dropout* de 0,5, para aumentar a generalização. A última unidade de toda a estrutura é um classificador *softmax* de doze unidades, uma por cada atividade, em que se obtém uma probabilidade para cada. O treino de todo o modelo é efetuado com o otimizador ADAM, durante 500 *epochs* e com o tamanho de *batch* de 128 com o objetivo de minimizar a função de perda definida, no caso a entropia cruzada. No que diz respeito aos resultados, o modelo atingiu uma *accuracy* de 0,916 e uma *F1-score* de 0,939 para as atividades que não correspondem a transições, descendo esta métrica para 0,612 nesses casos.

Esteban Velásquez et al. [33] apresentam um modelo que conjuga uma CNN com LSTM onde, através da classificação do sinal EMG se consegue identificar a que músculo corresponde. Os músculos em estudo são o bíceps braquial e o tibial direito e esquerdo. O modelo implementado possui duas camadas CNN, seguida de uma camada *Fully-Connected* (FC), cujo *output* é utilizado como entrada para a LSTM. Por fim, duas camadas FC são implementadas, em que a de saída é constituída pela função de ativação *softmax*, permitindo obter a probabilidade da amostra pertencer a cada um dos quatro músculos. De modo a obter uma inicialização dos pesos da primeira camada CNN, foram utilizados *autoencoders*. Os autores relatam que o modelo foi treinado por 200 *epochs*, obtendo uma *accuracy* de 95% ao utilizar a técnica de inicialização de pesos e, caso contrário, uma *accuracy* de 92,56%.

3.3 Desafios Atuais dos Algoritmos de Detecção de Contrações Musculares

A partir da revisão de literatura desenvolvida é possível observar que os métodos de detecção através de limiar apresentam limitações, não sendo viáveis em sinais cuja morfologia se encontra alterada. Para além disso, nos restantes estudos são constituídas bases de dados de sinais simulados para o treino dos modelos. Esta abordagem pode comprometer os resultados quando os algoritmos são aplicados em diferentes contextos reais visto que, a complexidade e a variabilidade de sinais reais pode não ser representada adequadamente pelos dados sintéticos. Para além disso, é de extrema importância que sejam efetuados testes de implementação dos algoritmos em tempo real, para compreender os períodos de latência e a sua influência na classificação.

Na pesquisa de literatura desenvolvida, não se encontraram estudos relevantes de aplicação de modelos de DL com sinais EMG para fins de acesso a meios de comunicação, o que indica que existe a necessidade de estudos científicos que permitam o desenvolvimento deste tipo de tecnologias. Não obstante, sendo que estes sistemas de comunicação são utilizados em casos de doenças neurodegenerativas, evolutivas do ponto de vista de alterações no sinal EMG, é crucial o foco na procura da possibilidade de sistemas adaptativos, que garantam a robustez a possíveis alterações nos dados [44].

MATERIAIS E MÉTODOS

Este capítulo inclui uma descrição pormenorizada da metodologia adotada para atingir os objetivos enumerados na Secção 1.2. Primeiramente, são apresentadas as abordagens de investigação base para a elaboração da dissertação, seguida da caracterização detalhada de cada passo no âmbito do plano de trabalho delineado.

4.1 *Design Science Research e User Centered Design*

O estudo a desenvolver seguirá duas metodologias: *Design Science Research* (DSR) e *User-Centered Design* (UCD). A primeira é uma abordagem de desenvolvimento de projetos científicos e de conhecimento que visa resolver problemas em seis etapas iterativas, nomeadamente, a identificação e motivação do problema, definição dos objetivos a alcançar com a solução, design e desenvolvimento de um artefacto, demonstração, avaliação e comunicação [45]. Através da sua aplicação, é possível desenvolver soluções progressivamente aprimoradas para contextos reais. No âmbito da inovação em saúde, tem permitido a criação de metodologias teóricas e experimentais para abordar novos problemas [46]. A escolha da segunda metodologia deve-se à realização do estudo de caso em indivíduos com ELA, com foco no participante e nas suas necessidades. A sua participação ativa no processo de conceção e validação da solução desenvolvida revela-se crucial para o êxito deste trabalho [47].

4.2 **Desenvolvimento de uma Aplicação para Detecção *Online* e Inteligente de Contrações Voluntárias no sinal EMG**

Seguindo as etapas da metodologia descrita acima, os objetivos, apresentados na Secção 1.2, foram definidos tendo por base a informação recolhida pela revisão de literatura e em conjunto com as Terapeutas da Fala da APELA. A discussão com as profissionais de saúde forneceu uma perceção real das necessidades e dificuldades dos doentes, nomeadamente, no que diz respeito ao acesso às Tecnologias de Apoio à Comunicação. Neste sentido, realizou-se uma primeira visita à associação onde foi possível assistir a sessões

4.2. DESENVOLVIMENTO DE UMA APLICAÇÃO PARA DETECÇÃO ONLINE E INTELIGENTE DE CONTRAÇÕES VOLUNTÁRIAS NO SINAL EMG

de terapia da fala, nas quais as terapeutas trabalham com os pacientes o desenvolvimento das suas capacidades de utilização de dispositivos de comunicação, cujos exemplos são mencionados na Secção 2.2.2. Esta observação permitiu compreender de forma clara o problema existente e identificar o que pode ser desenvolvido para o colmatar.

No que diz respeito ao desenvolvimento do artefacto, conforme indicado pela metodologia, tratou-se de um processo iterativo até se atingir o protótipo final e todas as etapas serão descritas nas secções seguintes. Em resumo, passaram pela conceção de um protótipo inicial da interface para aquisição, visualização e classificação de momentos de contração no sinal EMG em tempo real, utilizando o método de *threshold*, que é o mais comum para este fim segundo a literatura. Posteriormente, realizou-se a demonstração e avaliação num paciente com ELA, finalizando assim a **primeira iteração**. A **segunda iteração** iniciou-se com o desenvolvimento do modelo de DL e a sua implementação na interface, incluindo o envio de comandos de controlo do computador associados aos padrões de ativação muscular detetados por um segundo algoritmo. Esta fase terminou com o teste numa população de 7 indivíduos saudáveis. A **terceira iteração** introduziu uma nova forma de controlo do computador, mais interativa e intuitiva para os participantes, culminando na demonstração e avaliação dos resultados em 31 indivíduos saudáveis e num grupo de participantes com patologia associada, cujo número não se encontrava previamente definido pois dependeria da agilização com as terapeutas da fala da APELA.

4.2.1 Primeira Iteração - Protótipo Inicial de Interface Gráfica

A aplicação foi estruturada utilizando como base o código disponibilizado no *GitHub* por João Rodrigues [48]. Esta consiste numa página principal com um conjunto de configurações onde, após o estabelecimento da comunicação com o dispositivo de aquisição, surge uma nova janela com a apresentação do sinal EMG em estudo.

Na página inicial encontram-se disponibilizadas algumas configurações, passíveis de alteração, nomeadamente: o *MAC Adress*, código identificador do dispositivo responsável pela aquisição do sinal; *Sampling Rate*, taxa de aquisição do sinal; *Buffer Size*, valor que define o tamanho do vetor que armazena os dados adquiridos pelo dispositivo; *Duration*, definida como 0 para uma recolha de duração ilimitada, caso contrário, altera-se o valor para o pretendido; *Moving Average*, tamanho da janela do filtro de média móvel aplicada ao sinal. No código desenvolvido é possível definir quais os valores que surgem preenchidos por *default* em cada um dos campos, para evitar que o utilizador necessite de os reescrever antes de cada inicialização da aplicação.

Após a conclusão da comunicação com o dispositivo, uma nova janela é automaticamente exibida, permitindo a observação do sinal EMG em tempo real sem qualquer método de processamento implementado. Para estruturar o primeiro protótipo de interface destinado às pessoas com ELA, implementou-se um segundo gráfico com o resultado da aplicação de um conjunto de métodos de processamento de sinal. O objetivo era obter, na zona inferior da janela, o sinal EMG suavizado conjuntamente com um método de

deteção de contrações musculares baseado na definição de um *threshold*, apesar das limitações discutidas na Secção 3. Com esta aplicação desenvolvida, foi possível estabelecer um primeiro contacto com as pessoas com ELA e, posteriormente, substituir este método pelo algoritmo de DL a ser desenvolvido.

A aplicação foi estruturada utilizando a biblioteca *Python multiprocessing*, que permite a execução paralela de diferentes funções e a partilha de informação entre processos [49]. Desta forma, foram desenvolvidos três processos que operam de forma simultânea, nomeadamente:

1. **Processo de "Aquisição do Sinal"**: permite executar em *loop* a função de aquisição do sinal EMG bem como o armazenamento dos valores recolhidos num *buffer* partilhado, acessível a partir dos restantes processos. A arquitetura responsável pela comunicação com o dispositivo e respetiva recolha de sinal foi desenvolvida com base no código *open-source* disponibilizado pela empresa PLUX Wireless Biosignals [50].
2. **Processo de "Processamento de Sinal"**: responsável por aceder aos dados adquiridos a partir do *buffer* partilhado e aplicar o conjunto de métodos de processamento descritos na Subsecção 2.4.1. Para o filtro de média móvel foi definido, por *default*, uma janela de 250 amostras e o resultado do processamento de sinal é armazenado num *buffer* partilhado, para realização do gráfico e da deteção de contrações com recurso a um *threshold*.
3. **Processo de "Deteção de Contrações Musculares"**: recebe os valores do sinal EMG processado e possui a implementação que verifica se algum valor armazenado no vetor ultrapassa o *threshold* definido, inclusivamente as 80 amostras seguintes, evitando alguns falsos positivos. Caso a condição se verifique, é colocado um ponto vermelho que identifica o início da contração.

Para desencadear o processo enumerado em 3. é necessário definir o valor do *threshold*, embora já se encontre apresentado um valor por *default*. De seguida, pressionando o botão "Start Detection" apresentado na interface, surge uma linha a tracejado que indica o limiar selecionado. Deste modo, no contexto em que se aplicam as Tecnologias de Apoio à Comunicação, é facultada ao terapeuta a possibilidade de definir o valor mais adequado.

Para o design da interface, foi seguida a utilização das bibliotecas *Python* já previamente implementadas pelo autor do código, nomeadamente *PySide2*, que corresponde ao módulo *Python* oficial para aceder a uma ferramenta de desenvolvimento de interfaces gráficas denominada *Qt* [51].

4.2.2 Algoritmo de *Deep Learning*

Com o primeiro protótipo concluído, deu-se início à próxima etapa que envolve o desenvolvimento de um modelo de DL capaz de detetar automaticamente as contrações

4.2. DESENVOLVIMENTO DE UMA APLICAÇÃO PARA DETECÇÃO ONLINE E INTELIGENTE DE CONTRAÇÕES VOLUNTÁRIAS NO SINAL EMG

musculares. Esta abordagem visa introduzir inteligência na aplicação desenvolvida e substituir o método de detecção baseado na aplicação de um limiar.

4.2.2.1 Descrição da Base de Dados de Sinais Eletromiográficos

Os sinais eletromiográficos utilizados no estudo foram previamente adquiridos por Maria Marta Santos no âmbito da sua tese de Mestrado "Study of the electromyographic signal dynamic behavior in amyotrophic lateral sclerosis (ALS)"[52]. O equipamento utilizado foi o Bioplux, com uma taxa de aquisição de 1000 Hz, sendo que o protocolo de aquisição passou por 3 segundos de abdução dos dedos seguido de 3 segundos de relaxação num total de 6 minutos ou até o sujeito aguentar. Foram adquiridos sinais na mão direita (canal 3), mão esquerda (canal 1), antebraço direito (canal 4) e antebraço esquerdo (canal 2). Os sensores foram colocados no primeiro músculo interósseo dorsal, no caso da mão, e no músculo extensor comum dos dedos para o antebraço, num total de 33 sujeitos saudáveis e 24 sujeitos com ELA.

No estudo desenvolvido, foram utilizados exclusivamente os sinais recolhidos dos indivíduos saudáveis, devido à falta de qualidade dos sinais adquiridos dos participantes com patologia. Além disso, a grande variabilidade das características dos sinais, resultante dos diferentes estadios da doença, poderia dificultar a aprendizagem de características pelo modelo de DL. Por fim, a impossibilidade de realizar o *labelling* de forma correta, pela falta de informação e descrição detalhada do processo de aquisição, bem como de eventuais alterações que podem ter surgido durante a recolha, foram fatores decisivos para que a abordagem da presente dissertação se baseasse apenas no conjunto de indivíduos saudáveis.

4.2.2.2 Labelling dos sinais EMG

Antes de iniciar o desenvolvimento da estrutura do modelo e o seu treino, foi necessário etiquetar os sinais de forma manual através de observação, utilizando a aplicação *Upalgo Labeling* desenvolvida pela empresa *Ezako - Time Series Solutions*. Este processo permitiu assinalar os momentos de contração/descontração e foi realizado com os 4 canais disponibilizados sobrepostos, visto que os movimentos foram efetuados de forma sincronizada, embora para a constituição da base de dados tenham sido considerados como independentes.

Para o *labelling*, foram utilizadas exclusivamente duas etiquetas, **One_click (OC)**, escolhida com base na utilização das intenções de movimento dos participantes para controlar a interface de comunicação, no sentido de realizar uma seleção, isto é, um clique. As zonas de repouso foram etiquetadas com **Rest (R)**.

4.2.2.3 Preparação dos Dados

Para proceder ao treino do modelo com 70% dos dados e ao teste com 30%, foi necessário criar um *dataset* contendo os sinais de todos os participantes, aos quais foi aplicado um




Figura 4.1: Esquema que descreve a Característica da Base de Dados utilizada para o Treino e Teste do modelo de *Deep Learning*.

janelamento de 150 ms com um *overlap* de 30%. O valor definido para a divisão em janelas está em conformidade com o limite de 300 ms referido na literatura como o mais adequado para a detecção de movimentos em tempo real [53, 54]. No entanto, ao unir os sinais de diferentes participantes para formar um conjunto único, era essencial garantir que não ocorressem eventos como:

- Um sinal terminar num momento de contração e o seguinte iniciar em repouso, pois, ao realizar a divisão em janelas, esta não corresponderia a uma transição típica num sinal EMG e poderia induzir informações erradas sobre as características do sinal.
- A linha de base de um sinal de um sujeito pode não coincidir com a de outro. Ao unir ambos os sinais, poderá surgir um desfasamento entre eles, que ao ocorrer numa única janela de classificação não é uma característica comum do sinal.

Para evitar os eventos enumerados, aplicaram-se técnicas de processamento. Primeiramente, foram retiradas todas as zonas de contrações que surgissem imediatamente no início e no fim do sinal, garantindo que todos os sinais começassem e terminassem em repouso. Em segundo lugar, foi subtraída a média de cada sinal para eliminar o *offset* e garantir que a *baseline* se encontrasse a zero. Desta forma, a união dos sinais comporta-se como um sinal único, conforme demonstrado no esquema ilustrativo da Figura 4.1.

Após a constituição da base de dados, foi atribuída a cada uma das janelas uma *label* única, seguindo duas abordagens distintas:

1. Janelas em que todas as amostras pertencem à classe OC ou R mantém-se a *label* para o conjunto. No caso de janelas que possuem amostras de ambas as classes, atribui-se a *label* "**Transition (T)**", uma vez que significa que se encontram numa zona do sinal que transita de uma posição de repouso para contração, ou vice-versa.
2. A segunda abordagem surge com uma alteração ao nível do tratamento de janelas que possuem amostras de ambas as classes, onde se atribui a *label* OC caso seja uma zona de transição de repouso para contração, caso contrário é associada à *label* R.

A justificação da escolha do primeiro método passa pela importância que a detecção dos momentos de transição demonstra, visto que seriam essas janelas o indicador do início da intenção de movimento e, por isso, corresponderiam ao momento exato em que se enviaria o comando de controlo da interface. Neste caso, o modelo teria um conjunto de três classes distintas para realizar classificação. O segundo método surge como possível alternativa e baseia-se na necessidade de evitar atrasos na detecção do início e fim da

4.2. DESENVOLVIMENTO DE UMA APLICAÇÃO PARA DETECÇÃO ONLINE E INTELIGENTE DE CONTRAÇÕES VOLUNTÁRIAS NO SINAL EMG

contração. Para tal, optou-se por considerar imediatamente a zona de transição no início do momento de contração como uma janela de ativação. Relativamente ao término da contração, o raciocínio foi o oposto, pois, nessa janela, o sujeito já teve a intenção de terminar o movimento, sendo assim considerada como uma janela de repouso.

4.2.2.4 Estrutura e Métodos de Avaliação de Resultados do Modelo

Após a revisão da literatura apresentada na Secção 3.2, a estrutura desenvolvida para o modelo de DL passa por um modelo híbrido entre uma CNN e uma LSTM. A escolha deste modelo foi baseada nos resultados satisfatórios observados nos estudos abordados e na capacidade desta rede ser escalável para outros objetivos, como a classificação de padrões de movimentos diferentes e mais complexos.

O modelo base é composto por uma camada de entrada que recebe um vetor de dimensão (1,150,1), seguida de duas camadas convolucionais unidimensionais, uma camada LSTM, uma camada densa e por fim a camada de saída com a implementação da função *softmax*, para o caso da primeira abordagem de *labelling*, e a função sigmóide no caso da segunda. O treino do modelo foi realizado num total de 10 *epochs* e com atribuição de pesos a cada uma das classes, para evitar desbalanceamento dos dados.

Após a análise dos resultados com o modelo descrito que permitiu a determinação da abordagem de *labelling*, foram implementadas duas funções de *callback*: a função *ModelCheckpoint*, que guarda o modelo à medida que a métrica definida é avaliada e tende a aumentar, e a função *EarlyStopping*, que interrompe o treino do modelo caso a métrica em análise não apresente melhorias durante um número definido de *epochs*, sendo guardado o último modelo que obteve o melhor desempenho. Para além disso, utilizou-se a função *Keras Tuner* da biblioteca *Keras* para a procura de hiperpâmetros, nomeadamente através da variação das funções de ativação, dimensão do *kernel*, número de filtros e unidades, que maximizem o desempenho, permitindo a obtenção de vários modelos distintos apenas com a estrutura base em comum.

Para avaliação dos resultados, foram calculadas métricas como *accuracy*, precisão, sensibilidade, cujas equações se encontram no Apêndice A e, analisada a matriz de confusão como definido na Secção 2.4.2.

4.2.3 Algoritmo de Classificação de Padrões de Ativação Muscular

Tendo em conta que se seguiu a segunda abordagem de etiquetagem e considerando que a segunda etapa consiste em controlar o computador através do envio de comandos é essencial assegurar que existe, de facto, a intenção de movimento. Assim, optou-se por analisar dois tipos de movimentos distintos, correspondendo a dois comandos diferentes para o computador, descritos como: Clique Curto (CC), uma contração seguida de repouso e Clique Longo (CL), manter a contração durante um período de tempo. Com esta metodologia, foi possível explorar um potencial método de acesso a um sistema de alarme,

que seria ativado com o CL. Por outro lado, o CC é útil para controlar a interface de comunicação, permitindo a seleção de opções.

Como o nome indica, este algoritmo opera através da detecção de padrões nas previsões do algoritmo de DL. Especificamente, um CC corresponde a um número finito de previsões "1"(OC) seguidas de 2 previsões "0"(R). Por sua vez, o CL é identificado quando esse mesmo número de previsões positivas é excedido sem que haja o repouso subsequente, ou seja, a contração é mantida por um período mais prolongado. Este método, ilustrado no esquema da Figura 4.2, permite evitar alguns falsos positivos na detecção de intenções de movimento, uma vez que não é enviado o comando para a interface ao primeiro "1" previsto pelo algoritmo de DL, que pode não ser correto.




Figura 4.2: Esquema Ilustrativo do Funcionamento do Algoritmo de Detecção de Padrões de Ativação Muscular para o Clique Curto.

Com o objetivo de avaliar o desempenho do algoritmo desenvolvido, é guardado um ficheiro *.txt* durante o teste, contendo informações sobre o momento de início e fim de cada clique, a ordem de ocorrência e o número de previsões de "1" e "0" para cada intenção de movimento. Além dessa informação, com o sinal EMG armazenado, é possível analisá-lo e realizar o *labelling* observacional e manual em duas classes: CC e CL. Desta forma, é viável comparar o que o participante realizou com o que foi detetado pelo algoritmo.

A análise de desempenho desenvolvida inclui os seguintes passos:

1. Contabilizar o número de cliques curtos e longos realizados em comparação com os detetados;
2. Contabilizar o número de falsos negativos associados a cada tipo de movimento;
3. Utilizar os sinais EMG adquiridos e avaliar o desempenho do modelo de DL em *offline*, conforme descrito na Secção 4.2.2;
4. Calcular o tempo de decisão, isto é, o tempo desde que o modelo prevê o primeiro "1" até que o comando no computador é executado e o tempo de intenção até à decisão, tempo desde o início da contração até que o clique seja detetado pela interface;
5. Calcular a sensibilidade para a detecção dos cliques.

4.2. DESENVOLVIMENTO DE UMA APLICAÇÃO PARA DETECÇÃO ONLINE E INTELIGENTE DE CONTRAÇÕES VOLUNTÁRIAS NO SINAL EMG

Considerando que o algoritmo analisado constitui uma classificação multiclasse, temos as seguintes definições para FN: quando a classe correta é CC, os FN incluem todos os CCs detetados como CLs, não identificados ou que surgem durante o repouso; quando a classe correta é CL, os FN são todos os CLs não detetados, detetados incorretamente como CCs, ou que ocorrem durante o repouso. Por sua vez, os VP são todos os CCs ou CLs detetados corretamente.

4.2.4 Segunda Iteração - Protótipo Inteligente da Aplicação com Controlo de uma Apresentação *PowerPoint*

Com a incorporação de ambos os algoritmos na aplicação *online*, definiu-se que para o CC é necessário um total de 2 a 20 janelas de previsões "1", seguidas de 2 classificações como "0". Assim, o CL é identificado quando existem 21 janelas de previsão "1" consecutivas, ou seja, a contração necessita de ser mantida por cerca de 5 segundos.

Para ilustrar o controlo do computador através do sinal EMG, foi estruturada uma apresentação *PowerPoint* onde, durante os testes, se o utilizador realizar um clique curto, ocorre a passagem de um slide, enquanto um movimento longo avança dois slides.

4.2.4.1 Participantes

Um total de 7 sujeitos saudáveis participaram na Sessão de Teste estando a sua informação sumarizada na Tabela A.1. Todos os voluntários assinaram um consentimento informado escrito para participar no estudo e deram autorização para a gravação do sinal EMG para propósitos educacionais. O protocolo foi aprovado pela Comissão de Ética da Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa (Referência CE_FCT_009-2024). Também nos testes desenvolvidos subsequentemente no grupo de saudáveis, durante a Terceira Iteração de desenvolvimento do Protótipo, foram recolhidos os mesmos dados dos participantes. No que diz respeito ao grupo com ELA a informação recolhida diferiu, sendo que se deu mais relevância a dados acerca da doença, nomeadamente, o tipo de ELA (fenótipo), idade do diagnóstico e pontuação na *ALS Functional Rating Scale-Revised* (ALSFRS-R).

4.2.4.2 Configuração de Aquisição

A atividade muscular foi medida utilizando um par de elétrodos Ag/AgCl, que foram colocados no músculo de acordo com o descrito no Protocolo de Aquisição na Secção 4.2.4.3, seguindo algumas recomendações dadas pela empresa Delsys [55]. O dispositivo utilizado foi o biosignalsplux MuscleBAN com o sensor de EMG, resolução de 16 bits, taxa de amostragem de 1000 Hz e com comunicação *Bluetooth* ou *Bluetooth Low Energy* que permite que os dados sejam processados e armazenados durante o teste num ficheiro *.txt* para posterior análise.

4.2.4.3 Protocolo de Aquisição

No que diz respeito à colocação do dispositivo, não foi definido previamente em qual dos membros superiores seria colocado, uma vez que no estudo caso em doentes com ELA o local dependerá dos movimentos que o participante ainda consiga executar. Contudo, os participantes saudáveis foram instruídos a realizar o mesmo movimento com o membro superior, dispondo a MuscleBAN no músculo Flexor Ulnar do Carpo (FUC), porém não se colocou imposição em qual dos lados. Para além disso, quando possível, também se realizou o teste colocando o dispositivo na face, nomeadamente, no músculo Masséter (M).

O Protocolo de Aquisição aplicado foi o seguinte:

1. O procedimento da aquisição foi explicado aos participantes, que assinaram o consentimento informado onde se encontrava a Informação ao Participante com todo o procedimento detalhado;
2. A zona da pele onde se colocou o dispositivo foi limpa com discos de algodão embebidos com álcool;
3. Os participantes foram instruídos a colocar o antebraço, da sua preferência, sobre a mesa com a parte anterior voltada para cima para garantir um melhor suporte e conforto durante a aquisição;
4. Foi solicitado que fiquem durante cerca de 20 segundos em repouso até que a aplicação inicie;
5. Foi pedido que realizassem uma flexão do punho seguida de uma extensão até à posição de repouso (CC) e, de seguida, a flexão do punho mantendo em contração até que se observe o acionamento do comando correspondente ao movimento longo, seguido de repouso. No caso do músculo Masséter foi instruído aos voluntários que realizassem a "contração da bochecha", sendo o movimento exemplificado pelo autor. A sequência foi repetida no total de 5 vezes;
6. Se houver um erro na deteção do clique realizado poderia ser solicitado ao participante que repetisse o movimento ou no caso do CL por vezes, que tentassem manter em contração mesmo que surgisse um CC errado.

É importante referir que não foi pedido ao participante que realizasse a sua contração voluntária máxima, pois o mesmo procedimento não seria viável nos sujeitos com ELA.

4.2.5 Terceira Iteração - Protótipo Inteligente da Aplicação com Controlo de um Vídeo na Aplicação *Youtube*

A terceira iteração surgiu da necessidade de modificar o número de janelas de sinal EMG classificadas como "1" para a deteção de um clique longo, reduzindo-o para 10. Além disso,

4.2. DESENVOLVIMENTO DE UMA APLICAÇÃO PARA DETECÇÃO ONLINE E INTELIGENTE DE CONTRAÇÕES VOLUNTÁRIAS NO SINAL EMG

a abordagem do *PowerPoint* foi substituída pelo controlo de um vídeo do *YouTube*, em que o clique curto inicia/pausa o vídeo e o clique longo avança o vídeo quatro vezes, cada uma com duração de 5 segundos.

4.2.5.1 Testes em Participantes sem Patologia Associada

Desenvolveu-se um conjunto de testes para o novo protótipo, seguindo o mesmo protocolo de aquisição descrito na Subsecção 4.2.4, mas aplicado a um grupo de 31 participantes, cuja informação está sumarizada na Tabela A.2. A única alteração introduzida foi a inclusão de um período inicial durante o qual os participantes podem testar e aprender a realizar o CC e o CL, antes de iniciarem o protocolo. De salientar que, para a análise de resultados dessas contrações e os respetivos cliques detetados como teste serão eliminados.

4.2.5.2 Análise dos sinais EMG adquiridos

Com o objetivo de constituir uma base de dados com os sinais adquiridos, aplicou-se uma análise em amplitude, frequência e qualidade a cada sinal. Como tal, calculou-se a amplitude máxima, mínima e média com o respetivo desvio padrão, bem como a frequência mediana, frequência em que ocorre a potência máxima, potência total do sinal e a Raiz Quadrática Média, do termo em inglês *Root Mean Square* (RMS). Para avaliar a qualidade do sinal foi calculada a SNR, métrica principal que indica o rácio entre o sinal EMG em contração versus o ruído elétrico, indesejado, presente durante o repouso [56]. O cálculo foi realizado através do isolamento de todas as zonas do sinal em contração e em repouso, isto é, em vez de se proceder à escolha de uma única zona de ativação e de repouso, realizou-se a média de todas as zonas de contração e todas as zonas sem ativação.

4.2.5.3 Testes em Participantes com Patologia Associada

Considerando o objetivo do desenvolvimento da interface, a última fase envolveu a testagem em participantes com ELA, em parceria com a APELA. Neste grupo, aplicou-se o mesmo protocolo de aquisição, privilegiando a recolha de sinal nos músculos da face, nomeadamente no Masséter, por indicação das Terapeutas da Fala, pois estes tendem a permanecer funcionais por um período de tempo mais prolongado. Contudo, deixou-se em aberto a possibilidade de recolha noutra músculo, caso algum participante tivesse limitações. A única imposição era que o músculo fosse funcional e controlável de forma voluntária. Neste sentido, não foi definido previamente um número de participantes, pois dependia da disponibilidade da Associação e da coordenação com as sessões de Terapia da Fala. Foi possível realizar testes num total de 16 participantes, cuja informação está sumarizada na Tabela A.3.

O estudo do desempenho dos algoritmos para este conjunto de participantes seguirá a mesma metodologia aplicada anteriormente. Contudo, é crucial comparar os dois grupos quanto às características dos sinais e à influência da doença nas alterações observadas, que podem afetar a deteção das intenções de movimento.

RESULTADOS E DISCUSSÃO

Este capítulo está dividido em cinco secções: três dedicadas às iterações de desenvolvimento da aplicação para a deteção em tempo real de contrações voluntárias no sinal EMG, duas focadas na análise dos resultados dos métodos aplicados para o desenvolvimento do modelo de DL e do algoritmo de deteção de padrões de ativação muscular. As discussões que se seguem baseiam-se nas metodologias descritas no Capítulo 4.

5.1 Primeira Iteração - Protótipo Inicial da Interface Gráfica

A página principal da aplicação, mostrada na Figura B.1, Apêndice B, segue a estrutura descrita na Subsecção 4.2.1. Analisando a *performance* da aplicação, esta foi afetada pela presença de ambos os gráficos, conforme ilustrado na Figura B.2a, que causaram bloqueios e atrasos. Assim, decidiu-se manter apenas o gráfico inferior com o sinal processado, para uma visualização mais clara, como demonstrado na Figura B.2b. No entanto, ainda ocorria algum bloqueio ao tentar alterar o *threshold* após a primeira definição contudo, como não era para manter a deteção com este método não se realizou nenhuma melhoria.

Na experiência realizada na APELA com um paciente com ELA, constatou-se que a deteção de contrações musculares por limiar não é eficiente pois, por exemplo, a fadiga causa alterações na amplitude após algumas contrações. Adicionalmente, um limiar não otimizado aumenta as falsas deteções e exige ajustes frequentes, tornando o sistema pouco funcional e frustrante, podendo levar ao seu abandono. Para além disso, tanto as Terapeutas da Fala como o doente deram o seu *feedback* e reportaram a necessidade de desenvolver e investir em um sistema inteligente para as TAs à comunicação.

5.2 Algoritmo de *Deep Learning*

5.2.1 Constituição da Base de Dados de Sinais Eletromiográficos

Após a análise dos 132 sinais EMG decidiu-se eliminar 58 devido à sua baixa qualidade que poderia comprometer o desenvolvimento do modelo. Um exemplo de um sinal descartado está na Figura 5.1. A base de dados final consiste em 74 sinais, cada um com

aproximadamente 6 minutos de duração. O processo de *labelling* dos sinais, ilustrado na Figura 5.1, envolveu a inspeção manual, conforme mencionado anteriormente. Embora essa inspeção tenha apresentado desafios, especialmente na determinação precisa dos instantes de início e fim das contrações musculares, mostrou-se um método eficiente, não havendo evidências de que tenha um impacto negativo na *performance* do modelo.




Figura 5.1: Exemplo de um Sinal EMG eliminado durante o processo de *Labelling* (à esquerda) e de um Sinal EMG *labelled* utilizando a aplicação *Upalgo Labeling* (à direita).

5.2.2 Sessão *Offline* de Treino

Seguindo a primeira abordagem de *labelling* das janelas de amostras procedeu-se ao treino do modelo híbrido com a segmentação em janelas de 150 ms e 300 ms ambos com 30% de *overlap*, obtendo-se as matrizes de confusão representadas na Figura 5.2.

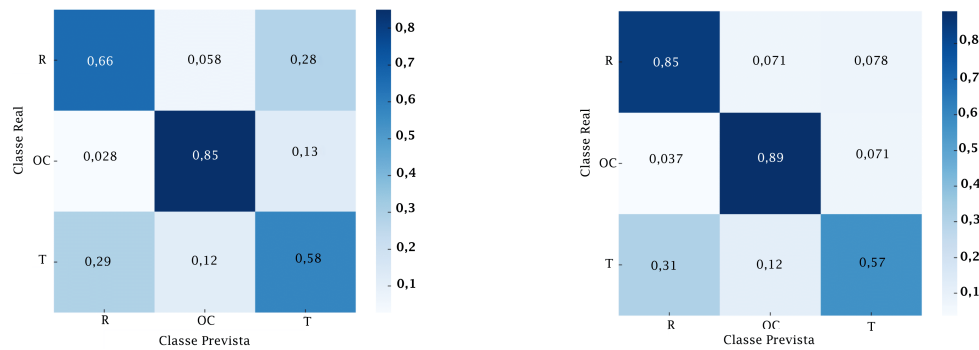



Figura 5.2: Matriz de Confusão para a classificação de janelas em três classes, Rest (R), One_Click (OC) e Transition (T). À esquerda a divisão em janelas foi realizado com dimensão de 150 ms e à direita com 300 ms ambos com *overlap* de 30%.

A análise da *performance* do modelo variando a dimensão da janela, resultou da Tabela B.1, onde se procurou entender como a alteração deste parâmetro e do *overlap* poderia trazer resultados mais satisfatórios, reduzindo o desbalanceamento entre classes. Concluiu-se que o uso de 300 ms e 30% de sobreposição traz melhorias, mas como a classificação das janelas em T é a mais relevante, as diferenças observadas não justificam que se mantenha essa abordagem de *labelling*. Uma possível solução seria aumentar a quantidade de dados, focando no número de contrações realizadas em cada aquisição, em vez de obter contrações de longa duração. Esse protocolo aumentaria a quantidade de janelas T em relação às outras classes.

Implementando a segunda abordagem de atribuição de classes às janelas de sinal, estudou-se o desempenho do mesmo modelo, mantendo a sua estrutura, alterando apenas a função de ativação da camada de saída e utilizando janelas de 150 ms com 30% de *overlap*. Os resultados, representados através da matriz de confusão na Figura 5.3a, indicaram uma *accuracy* de 88,6%, precisão de 92,3%, sensibilidade de 87,8% e *F1-Score* de 90,0%.

Este conjunto de resultados mostrou-se bastante satisfatório, com ambas as classes apresentando uma taxa de acerto próxima de 90%. No entanto, foram testados mais cinco modelos, cujas características se encontram descritas na Tabela B.2, com estruturas semelhantes, mas com variações nas funções de ativação, tamanho do *kernel*, número de filtros e unidades. Esses modelos foram gerados pelas funções, descritas na metodologia, que realizam a busca da melhor combinação de hiperparâmetros bem como de resultados durante o treino. Contudo, embora alguns dos modelos apresentem os mesmos parâmetros, o seu desempenho na classificação varia pelas diferenças de pesos associados às camadas. Os resultados desses modelos estão resumidos na Tabela B.3 do Apêndice B.

Dado que as métricas apresentam valores iniciais satisfatórios, realizaram-se testes adicionais para avaliar o desempenho dos modelos com 4 novos sinais adquiridos pelo dispositivo MuscleBAN, sem qualquer processamento prévio. Esses testes visaram compreender a *performance* do modelo, em *offline*, utilizando sinais semelhantes aos que serão adquiridos em tempo real.



(a) Matriz de Confusão para a segunda metodologia de *labelling*. (b) Matriz de Confusão para teste do modelo em 4 sinais EMG novos.

Figura 5.3: Matrizes de Confusão com os resultados da implementação da segunda metodologia de *labelling* na base de dados (à esquerda) e com o teste do modelo em sinais adquiridos com a MuscleBAN (à direita).

Os resultados mostraram que apenas o modelo 1 manteve um desempenho consistente com o treino, apresentando uma *accuracy* de 92,3%, precisão de 91,1%, sensibilidade de 86,3%, *F1-Score* de 88,6% e especificidade de 95,5%, como ilustrado na Figura 5.3b. Os outros modelos previram apenas “1”, o que pode ser resultado das modificações na amplitude dos sinais durante o treino, já que a remoção da média resultou numa diminuição global da mesma. Estes aparentam ter extraído *features* baseadas na amplitude e ao serem confrontados com sinais de amplitude mais elevada, classificaram tudo como “1”. Assim, o primeiro modelo foi o que demonstrou maior robustez na classificação de sinais cujas

características serão semelhantes aos adquiridos em tempo real.

Para evitar os resultados observados nos restantes modelos, uma abordagem alternativa poderia ter sido treinar com os dados de cada indivíduo separadamente, sem agrupar todos os sinais num único ficheiro e testar da mesma forma. Adotando esta metodologia, o processamento aplicado poderia ter sido evitado. Outra opção seria manter os dados de teste sem a alteração da média para avaliar o comportamento dos modelos nessas condições, além de aplicar técnicas para evitar um possível *overfitting*, como *dropout* ou normalização do *batch*.

5.3 Algoritmo de Classificação de Padrões de Ativação Muscular

O processo de desenvolvimento do algoritmo foi iterativo, no sentido em que se foi aprimorando a deteção à medida que se realizavam tentativas e experiências. Como tal, foi necessário ajustar o modelo introduzindo verificações, nomeadamente, a ocorrência de uma classificação "0" entre um conjunto de "1"s não poderia ser considerada, pois será apenas uma classificação errada por parte do modelo, acontecendo o mesmo no caso da classificação como "1" durante um período de repouso.

Para além disso, compreendeu-se que o modelo de DL apresenta um atraso de classificação superior durante a implementação em tempo real do que em *offline*, passando de cerca de 80 ms para cerca de 200 ms o que é superior ao tamanho da janela de sinal que é classificada. Isto permitiu concluir que a classificação em janelas é realizada sem *overlap*, contrariamente ao que acontece durante o treino, o que poderá interferir com os resultados. Contudo, só é possível afirmar quando forem realizados os testes num conjunto de indivíduos.

5.4 Segunda Iteração - Protótipo Inteligente da Aplicação com Controlo de uma Apresentação *Power-Point*

Ao aplicar o protocolo experimental descrito na Secção 4.2.4.3 a 7 indivíduos, constatou-se que apresentavam dificuldade em manter a contração pelo tempo necessário para a deteção do CL, resultando em deteções como CCs. A apresentação *PowerPoint* desenvolvida continha dois tipos de slides, "Clique Curto" e "Clique Longo", dispostos conforme a sequência solicitada no Protocolo de Aquisição. No entanto, devido às falhas na deteção do movimento longo, o conteúdo dos slides frequentemente não correspondia ao que era realizado e solicitado, causando descoordenação nos movimentos e aumentando os erros. Além disso, os participantes manifestaram a necessidade de realizar cliques de teste para aprenderem a executar corretamente o movimento.

Os testes realizados permitiram perceber que a apresentação não é a forma mais eficiente e intuitiva de fornecer *feedback* visual. Concluiu-se que, além de reduzir o tempo necessário para a deteção do CL, era fundamental encontrar uma abordagem alternativa

para exemplificar o uso de interfaces homem-computador. Adicionalmente, era essencial incluir no protocolo experimental um período de aprendizagem dos movimentos, para que os participantes se possam familiarizar com o sistema. Esta necessidade de ajuste reflete a importância da metodologia escolhida para o desenvolvimento do trabalho, destacando que, sendo uma tecnologia destinada a pessoas, o seu contributo e envolvimento são cruciais para o sucesso do projeto.

5.5 Terceira Iteração - Protótipo Inteligente da Aplicação com Controlo de um Vídeo na Aplicação *Youtube*

A recolha de dados foi inicialmente realizada com 31 voluntários, sendo 20 do sexo feminino e 11 do sexo masculino, com idades entre os 21 e 37 anos. A média de idade foi de 23 anos para as mulheres (desvio padrão de 2 anos) e 24 anos para os homens (desvio padrão de 4 anos). No total, foram adquiridos 47 sinais EMG: 31 no músculo FUC e 16 no músculo M.

O novo método de interação com a interface, utilizando um vídeo na plataforma *YouTube* mostrou-se intuitivo, sem comprometer a concentração ou coordenação dos participantes. Também o tempo para a deteção do CL foi considerado adequado.

Com o feedback positivo, foram desenvolvidos testes em 16 indivíduos com ELA, em coordenação com a APELA, sendo 8 de cada sexo, com idades entre os 46 e 74 anos. A média de idade foi de 59 anos para as mulheres (desvio padrão de 9 anos) e 55 anos para os homens (desvio padrão de 8 anos). Entre os participantes, 4 apresentavam o tipo de ELA Misto, 2 Medular, 3 Primária, 6 Bulbar e 1 Respiratória. Foram adquiridos 17 sinais EMG: 14 no músculo M, 2 no vasto medial do Quadríceps Femoral e 1 no FUC. Na Secção seguinte será realizada a análise comparativa de ambos os grupos de participantes.

5.5.1 Análise em Qualidade, Amplitude e Frequência dos sinais EMG

De entre os 47 sinais saudáveis adquiridos, eliminou-se para o estudo dos resultados dois sinais, um recolhido na face do participante H_GG e outro no antebraço do participante H_V, ilustrados na Figura 5.4, devido a problemas na aquisição que levaram a incumprimentos do protocolo de aquisição.




Figura 5.4: Sinais EMG adquiridos no participante H_V (à esquerda) e H_GG (à direita).

5.5. TERCEIRA ITERAÇÃO - PROTÓTIPO INTELIGENTE DA APLICAÇÃO COM CONTROLO DE UM VÍDEO NA APLICAÇÃO YOUTUBE

Em relação aos participantes com patologia, foi excluído apenas o sinal do voluntário ALS_A6 pois, devido ao estado bastante avançado da doença não foi possível cumprir o protocolo estabelecido, tendo realizado apenas três contrações voluntárias. Assim, em análise ficaram 45 sinais EMG do grupo saudável e 16 do grupo com ELA.

A partir dos valores apresentados na Tabela B.4 foram construídos gráficos de extremos e quartis, conhecidos como *boxplots*, para a relação sinal-ruído e amplitude máxima das amostras, Figura 5.5, que permitem visualizar a distribuição dos dados. Comparando os valores de SNR para os dois músculos, observa-se que no FUC há maior variabilidade incluindo *outliers*, com dois casos acima do esperado e um abaixo do mínimo. Em contraste, os valores no Masséter são mais consistentes e tendencialmente inferiores. Como a SNR depende da amplitude do sinal, os valores máximos inferiores no M podem reduzi-la, assumindo o ruído constante. Além disso, a colocação do dispositivo na face onde fica suspenso, aumenta a suscetibilidade a mau contacto entre os elétrodos e a pele, incrementando o ruído na linha de base. Ao observar o gráfico da amplitude máxima na Figura 5.5 à direita, verifica-se que os valores apresentam uma maior variação relativamente ao FUC do que para o músculo M. Fisiologicamente, essas diferenças podem ser atribuídas tanto à estrutura distinta dos músculos quanto à maior facilidade dos participantes em realizar contrações de maior amplitude, no músculo do antebraço em comparação com o da face, resultando em valores mais elevados para o FUC.




Figura 5.5: Variação da SNR (dB) (à esquerda) e Amplitude Máxima (mV) (à direita) para o grupo de participantes saudáveis.

Os sinais com pior SNR foram os do participante H_Z com 11,0 dB (músculo FUC) e dos indivíduos H_DD, H_HH e H_KK (músculo Masséter), com 12,1 dB, 8,1 dB e 12,0 dB, respetivamente. Nos casos de H_HH e H_KK, a baixa qualidade do sinal foi devido ao mau contacto entre a pele e o elétrodo causado pela barba, levando até ao descolamento dos elétrodos. Idealmente, os pelos devem ser removidos das áreas onde os elétrodos são colocados para evitar a ocorrência deste tipo de problemas. Na Figura 5.6 encontram-se dois exemplos dos sinais anteriormente enumerados.

Para os participantes com ELA os resultados encontram-se na Tabela B.5 e os *boxplots*, Figura 5.7, foram construídos apenas para o músculo Masséter, indicando uma mediana de amplitude máxima ligeiramente inferior à anterior, mas com um valor máximo mais elevado. Considerando que esta métrica corresponde à amostra com maior amplitude, no caso da ELA, pode ser um indício da presença de potenciais de ação com amplitudes muito elevadas, o que é uma evidência de alterações neurogénicas crónicas [57].




Figura 5.6: Sinais EMG adquiridos no participante H_Z (à esquerda) e H_HH (à direita)




Figura 5.7: Variação da SNR (dB) (à esquerda) e Amplitude Máxima (mV) (à direita) para o grupo de participantes com ELA.

A RMS do sinal é uma métrica que permite avaliar a intensidade da atividade muscular [58]. Observa-se, pela Figura 5.8, que a mediana da RMS é superior no grupo sem patologia, indicando intensidades de contração mais elevadas. No entanto, a variação dos valores é significativamente maior no grupo com patologia, refletindo as diferentes fases da doença e as consequentes alterações musculares que influenciam o sinal EMG.




Figura 5.8: Variação da RMS para o grupo sem patologia (à direita) e com patologia (à esquerda).

Em termos de análise em frequência, é interessante comparar os espectros de densidade espectral de potência para um sinal saudável, participante H_NN no músculo M e um sinal de um indivíduo com patologia, participante H_OO no músculo M, onde sejam visíveis alterações resultantes da doença, nomeadamente, a presença de fasciculações na zona de repouso. Os sinais EMG em estudo encontram-se ilustrados na Figura 5.9.

Ao analisar os espectros presentes na Figura 5.10, observa-se que, no saudável a energia do sinal está concentrada principalmente entre 0 e 150 Hz, enquanto no espectro do participante com ELA a distribuição é mais ampla, com picos mais evidentes entre os 100 e 200 Hz. Este padrão pode ser resultado de disparos mais irregulares e anormais das unidades motoras, típicos da degeneração dos neurónios motores. Além disso, a potência mais elevada é alcançada próxima dos 200 Hz, em contraste com o valor abaixo de 100 Hz observados em pessoas saudáveis, sugerindo um recrutamento de unidades motoras

5.5. TERCEIRA ITERAÇÃO - PROTÓTIPO INTELIGENTE DA APLICAÇÃO COM CONTROLO DE UM VÍDEO NA APLICAÇÃO YOUTUBE




Figura 5.9: Sinais EMG adquiridos no participante H_NN (à esquerda) e ALS_OO (à direita).

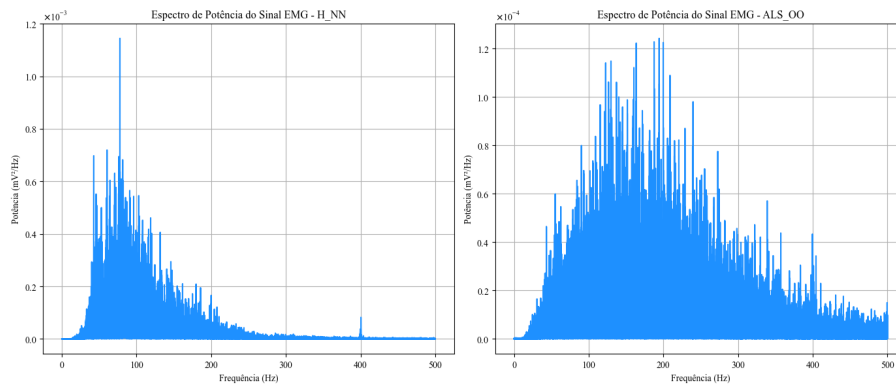


Figura 5.10: Espectro de densidade espectral de potência para o sinal EMG adquirido no participante H_NN (à esquerda) e ALS_OO (à direita).

de acionamento mais rápido. Globalmente, a potência em cada frequência é cerca de uma ordem de grandeza inferior no indivíduo com ELA em comparação a uma pessoa saudável, possivelmente devido à perda de unidades motoras e à atrofia muscular.

5.5.2 Análise do Desempenho *Offline* do modelo




Figura 5.11: Matriz de Confusão para a classificação *offline* dos sinais adquiridos na Terceira Iteração para o grupo de participantes saudáveis (à esquerda) e com ELA (à direita).

No grupo de saudáveis obteve-se uma *accuracy* de 90,5%, precisão de 96,6%, sensibilidade de 73,2%, *F1-Score* de 83,3% e especificidade de 98,8%. Em comparação, o grupo com ELA apresentou valores inferiores, com *accuracy* de 81,1%, precisão de 96,6%, sensibilidade de 41,9%, *F1-Score* de 58,4% e especificidade de 99,3%. Esses resultados, indicam que o

desempenho do modelo piorou na classificação de sinais de pessoas com ELA, o que era esperado, já que o treino foi feito em sinais de pessoas saudáveis, cujas características diferem. Além disso, o treino com sinais dos membros superiores, em contraste com o teste em sinais do Masséter em pessoas com ELA, também pode ter influenciado a classificação, pois são músculos diferentes com características distintas que se podem traduzir no sinal EMG. O maior erro de classificação, conforme as matrizes de confusão da Figura 5.11, foi a confusão entre OC e R, aumentando os falsos negativos na detecção dos movimentos.

5.5.3 Análise do Desempenho em Tempo Real do Sistema desenvolvido

5.5.3.1 Grupo de Participantes Saudáveis

Entre os 45 sinais adquiridos, falhas na detecção das intenções de movimento foram observadas em 24. Essas falhas incluem cliques não detetados, cliques durante períodos de repouso e cliques incorretamente identificados (CL detetado como CC). Para ilustrar esses dados foram criados os gráficos de barras presentes na Figura B.3. Globalmente, houve mais falhas na detecção do CL, o que era esperado devido à maior dificuldade de execução e à maior suscetibilidade de ser identificado como CC. Isso ocorre porque basta que dois vetores sejam erradamente classificados como "0" durante uma contração prolongada para que a sequência seja interpretada como CC.

A falha mais comum nos CCs é a não detecção, que geralmente ocorreu uma vez por teste, sendo mais frequente no músculo Masséter. Este erro surge porque os cliques são realizados muito rapidamente, não cumprindo o tempo necessário para classificar de, no mínimo, duas janelas "1" seguidas de duas janelas "0", que surgem frequentemente quando há quedas na amplitude. Esse problema é agravado pelo *delay* médio de 200 ms na classificação, uma vez que é superior ao tamanho de uma janela, bem como por erros na classificação das primeiras janelas de contração por parte do modelo de DL. Assim, o que deveria ser detetado em 600 ms de sinal acaba por exigir cerca de 1,4 segundos para ser corretamente identificado.

Um CC detetado como CL observou-se apenas no participante H_DD durante a aquisição no músculo FUC. A análise do sinal mostra que não houve uma descontração muscular completa, o que foi observado também durante a aquisição. Embora o participante tenha alcançado a extensão do punho, possuía alguma tendência em manter o músculo contraído em vez de relaxado, o que pode ter causado picos no sinal. Estes podem ter sido classificados pelo modelo de DL como "1", resultando na detecção incorreta do padrão de ativação CL.

A detecção de CCs durante o repouso ocorreu apenas no participante H_HH, no músculo Masséter. Esses falsos cliques surgiram no período de repouso após o teste, devido a um aumento progressivo do ruído cuja causa já foi discutida anteriormente. A Figura 5.12 apresenta exemplos de cada um dos casos descritos.

Os gráficos de barra mostram que o CL apresenta um maior número de falhas. A análise individual dos participantes revelou que, durante contrações mais longas, por

5.5. TERCEIRA ITERAÇÃO - PROTÓTIPO INTELIGENTE DA APLICAÇÃO COM CONTROLO DE UM VÍDEO NA APLICAÇÃO YOUTUBE




Figura 5.12: Exemplos de FN na deteção das intenções de movimento. À esquerda é ilustrado um CC não detetado, a imagem central mostra um CC detetado como CL e à direita CC/CL identificados durante o repouso.




Figura 5.13: Exemplo de CLs detetados como CCs no participante H_GG.

vezes são detetados múltiplos CCs, o que contribui para os valores observados.

No caso do participante H_GG, no músculo FUC ilustrado na Figura 5.13, essas falhas são justificáveis pelas quebras acentuadas na amplitude durante as contrações. Constata-se que, o modelo de DL tende a classificar essas janelas como "0", o que conduz a erros na deteção. Além disso, a baixa amplitude global contribui para maiores erros na classificação. Outros exemplos de sinais EMG onde oscilações na amplitude podem ter causado má deteção encontram-se representados na Figura B.5 no Apêndice B.

Contudo, nem sempre os CCs erradamente detetados durante CLs ocorrem devido à diminuição de amplitude. No caso do participante H_BB, analisando o sinal no músculo FUC, a amplitude não apresenta de forma evidente quebras acentuadas mas, em 4 CLs foram detetados apenas CCs. Em duas dessas tentativas, a deteção foi correta após o voluntário repetir o movimento, exceto no último CL. Neste caso, não está claro o que causou a classificação de janelas como "0" durante a contração, resultando na deteção de CCs. Possivelmente, o modelo de DL pode ter identificado alterações no sinal não diretamente relacionadas com a amplitude. Tanto para H_BB e H_GG no músculo FUC quanto para H_KK no músculo Masséter, o modelo apresentou uma *accuracy* abaixo de 80% e sensibilidade inferior a 50%, indicando uma alta quantidade de FN que impacta negativamente a deteção dos CLs.

5.5.3.2 Grupo de Participantes com ELA

Analisando os gráficos de barra da Figura B.4, no grupo de participantes com patologia verificou-se a não deteção de cliques em dois casos, ALS_A2 e ALS_VV, situação que não ocorreu no grupo anterior. A análise dos sinais, apresentados na Figura 5.14, mostrou que

a amplitude máxima atingida foi muito baixa, cerca de 0,1 mV, indicando contrações de baixa intensidade. Ambos os sinais apresentaram SNR baixas, com 8,4 dB para ALS_A2 e 10,2 dB para ALS_VV, o que combinado com as baixas intensidades tem demonstrado afetar negativamente o desempenho da classificação. Como resultado, o modelo fez previsões incorretas, maioritariamente como "0", o que não permite a deteção dos padrões correspondentes aos cliques.




Figura 5.14: Sinais EMG dos participantes ALS_VV (à esquerda) e ALS_A2 (à direita).

Nos casos dos participantes ALS_SS, ALS_TT e ALS_ZZ houve deteção de cliques, mas a maioria foi classificada incorretamente. A análise da *performance offline* revelou uma quantidade muito reduzida de VP em comparação aos FN, resultando numa *accuracy* abaixo de 70% e sensibilidade de 5,39% para ALS_SS, 18,71% para ALS_TT e, no caso de ALS_ZZ, 11,7% no músculo FUC e 3,21% no quadríceps. ALS_SS apresentou SNR de 9,0 dB e amplitude máxima de 0,126 mV; ALS_TT teve uma SNR de 11,6 dB e amplitude de 0,146 mV; ALS_ZZ alcançou 0,164 mV de amplitude e SNR de 9,1 dB no FUC, enquanto para o quadríceps os valores foram de 0,111 mV e SNR de 14,4 dB. A análise da Frequência Mediana, associada à fadiga muscular, demonstrou que esses participantes apresentaram os valores mais baixos entre os 16 analisados, indicando alterações na capacidade contrátil do músculo [59]. Todos estes fatores associados, podem ser cruciais para alterar a *performance* do modelo que impacta diretamente a deteção dos cliques.

No sinal de ALS_SS, presente na Figura 5.15, a amplitude das contrações é bastante variável, sugerindo um recrutamento muscular inconsistente. Adicionalmente, durante os períodos de repouso, observam-se oscilações na amplitude que, embora possam ser atribuídas ao ruído, também podem ser indicativas de atividade involuntária. Devido às características da doença, a amplitude durante os CLs não é mantida de forma constante sendo que os três CCs identificados no gráfico ocorrem sempre na fase inicial dos CLs, nas zonas onde ocorre uma maior ativação muscular seguidas de uma diminuição. No entanto, como isso não se verifica em todos os CLs, não se pode estabelecer um padrão consistente ou uma relação direta.

A mesma situação ocorre para ALS_TT, Figura 5.16, com três deteções de CCs durante os CLs, embora dois CCs tenham sido corretamente identificados. No entanto, ao observar o sinal, percebe-se que as amplitudes entre as contrações são mais consistentes, demonstrando o participante uma maior capacidade de manter a contração. Ainda assim, isso não foi suficiente para garantir a correta deteção dos CLs.

Embora tenham sido destacados apenas alguns casos, outros participantes também

5.5. TERCEIRA ITERAÇÃO - PROTÓTIPO INTELIGENTE DA APLICAÇÃO COM CONTROLO DE UM VÍDEO NA APLICAÇÃO YOUTUBE




Figura 5.15: Sinal EMG do participante ALS_SS com identificação dos CCs detetados.




Figura 5.16: Sinal EMG do participante ALS_TT com identificação dos CCs detetados.

apresentaram uma elevada taxa de erro na deteção de cliques, ainda que tenha existido alguma deteção. Por exemplo, em ALS_A4, apenas dois CCs foram detetados corretamente e todos os CLs foram identificados com um ou mais CCs. Um CC foi detetado na zona de repouso no final do teste, possivelmente devido a atividade muscular involuntária. A *accuracy* do modelo foi de 73,6% e a sensibilidade de 28,9%, o que se traduz no mau desempenho da deteção das intenções de movimento. O sinal manteve-se dentro do padrão observado para o grupo com patologia, com uma SNR reduzida de 10,4 dB e amplitude máxima de 0,189 mV.

Por outro lado, as aquisições com taxas de erro mais baixas ocorreram nos participantes ALS_A1, ALS_OO, ALS_RR e ALS_UU. Nestes casos, a SNR variou entre 11,5 dB e 21,7 dB, com amplitudes máximas entre 0,282 mV e 0,393 mV, sugerindo que o modelo possui melhor desempenho com sinais de maior intensidade. As métricas refletem esse facto, com *accuracy* acima de 80% e sensibilidade acima de 60%, resultando em menos FN e mais VP. ALS_A3 e ALS_XX foram os únicos sem erros, apresentando *accuracy* de 96,1% e 93,6% e sensibilidade de 94,1% e 82,5%, respetivamente. Estes sinais apresentaram as SNRs mais elevadas, com amplitudes de 0,919 mV e 0,559 mV.

5.5.3.3 Comparação entre o Tempo médio de Decisão e Intenção-Decisão entre os dois grupos de voluntários

No que diz respeito à análise dos valores presentes na Tabela 5.1, o menor tempo de decisão para o CC no grupo com ELA resulta da maioria dos sinais terem sido adquiridos no Masséter, com contrações tendencialmente mais curtas. Enquanto nos saudáveis predominam sinais do FUC, cujo movimento solicitado ao participante requer mais tempo para a realização o que afeta os valores analisados. Para o CL, o tempo de decisão é superior no grupo saudáveis, contudo este valor pode ser influenciado pelos poucos casos de VP no

grupo com ELA, únicos considerados para esta análise. Em ambos os grupos, os tempos de intenção-decisão são superiores aos tempos de decisão, sendo mais relevante no grupo com patologia onde o modelo de DL apresenta uma *performance* inferior.

Tabela 5.1: Comparação entre o Tempo médio de decisão/intenção-decisão dos Cliques Curto e Longo para o grupo de participantes saudáveis e com ELA.

	Saudáveis		Com patologia associada	
	CC	CL	CC	CL
Tempo médio de decisão (s)	1,14 ± 0,30	2,04 ± 0,31	1,02 ± 0,31	1,17 ± 0,45
Tempo médio de intenção-decisão (s)	1,22 ± 0,48	2,24 ± 0,59	2,09 ± 0,43	2,18 ± 0,62

5.5.4 Resumo e Discussão Final dos Resultados

Ao longo do estudo dos resultados, verificou-se que a SNR e a amplitude são fatores que influenciam a classificação pelo modelo. A influência da SNR era esperada, já que os estudos de Francesco Di Nardo et al. e Ghislieri et al. (Capítulo 3) usaram diferentes valores desta métrica para testar e treinar os modelos, mostrando ser um fator relevante. No que diz respeito à amplitude, é importante notar que essa medida é sensível a diversos fatores, como as características fisiológicas, anatômicas e biomecânicas do músculo em estudo. O ideal seria normalizar a amplitude em relação a um valor de referência, como a amplitude durante a contração voluntária máxima [27], no entanto não é viável solicitar a sua realização ao grupo com patologia.

Comparando o desempenho do algoritmo, conclui-se que foi pior no grupo com ELA, pois a sensibilidade para a detecção das intenções de movimento foi 91,9% para o CC no grupo de saudáveis em comparação com os 59,1% para os participantes com ELA. O mesmo se constata para o CL, com resultados mais discrepantes, obtendo-se uma sensibilidade de 75,3% para os indivíduos sem patologia e apenas 39,3% para os indivíduos com patologia. Como já discutido, esta variação ocorre possivelmente pela presença de sinais mais ruidosos com amplitudes inferiores, resultantes do desenvolvimento da doença. Desta forma, embora o método de detecção em estudo se mostre bastante eficiente para o grupo de saudáveis é crucial garantir um melhor desempenho do modelo de DL para o grupo com ELA e, conseqüentemente, do algoritmo de detecção de padrões, garantindo uma melhor generalização na classificação de padrões de ativação potencialmente diferentes.

Assim, para alcançar melhores resultados, é necessário constituir bases de dados com sinais EMG patológicos. Neste sentido, esta dissertação contribui com uma base de dados de sinais EMG de participantes com ELA e saudáveis devidamente documentada, com inclusão dos sinais recolhidos com o respetivo *labelling*, que se pretende que seja disponibilizada para trabalhos futuros.

CONCLUSÃO E TRABALHO FUTURO

Nesta dissertação, demonstrou-se a viabilidade de uma interface homem-computador controlada por sinal eletromiográfico para acesso a sistemas de apoio à comunicação em indivíduos com ELA. O protótipo desenvolvido permitiu os primeiros testes de uma tecnologia baseada em modelos de DL para a classificação em tempo real de intenções de movimento em sinais EMG. O contacto com os doentes, através da parceria com a APELA, foi crucial para a definição dos requisitos da interface em desenvolvimento e para compreender a necessidade de desenvolver soluções que assegurem a capacidade de comunicação pelo máximo de tempo possível.

No decorrer deste trabalho, foi primeiramente necessário estruturar uma interface para aquisição e visualização em tempo real do sinal EMG, assegurando uma configuração simples do dispositivo de recolha e proporcionando informação útil tanto para o utilizador quanto para os terapeutas da fala. Em segundo lugar, para substituir o método de *threshold*, foi criado um modelo de DL capaz de classificar e identificar momentos de contração e descontração no sinal EMG. A introdução de inteligência no sistema era um dos principais objetivos do trabalho, demonstrando que esta abordagem é viável e pode evoluir para resultados significativamente melhores em comparação com os métodos tradicionais de deteção de ativações musculares. Para treinar o modelo, foi necessário realizar uma análise exploratória e o *labelling* de um conjunto de sinais EMG de indivíduos saudáveis, além de realizar o pré-processamento necessário para constituir a base de dados. Em seguida, o modelo foi implementado na interface, juntamente com o desenvolvimento de um segundo algoritmo para identificar padrões na sua classificação, com o objetivo de construir uma forma de controlo de computador que fornecesse *feedback* visual aos participantes durante os testes.

Visando validar o sistema desenvolvido e avaliar a sua performance realizaram-se testes com um grupo de 31 participantes sem patologia. Os resultados obtidos foram satisfatórios, com a deteção correta das intenções de movimento na maioria dos casos, ocorrendo a maior taxa de erro no CL. Observou-se que a qualidade do sinal adquirido e as oscilações de amplitude influenciam significativamente a correta classificação das janelas pelo modelo. Além disso, o CL diferindo do CC por apenas uma janela "1" sem

as janelas "0", torna-se mais suscetível a erros de classificação, podendo ser interpretado como CC. No grupo de participantes com ELA, o desempenho da interface mostrou-se mais problemático, sugerindo que o modelo de DL não lida tão bem com sinais patológicos. Portanto, pode não ser ideal treinar o modelo exclusivamente com sinais saudáveis. Em relação à realização de dois movimentos distintos, concluiu-se que, embora alguns participantes os consigam executar, outros apresentam maior dificuldade. No entanto, se não houvesse um tempo mínimo restrito para a detecção, a tarefa tornar-se-ia mais acessível para um maior número de pessoas. Este facto, corrobora a necessidade de aplicar métodos como HITL-ML para desenvolver sistemas adaptativos, que como o nome indica, se adaptem às características do sinal e capacidades de cada utilizador. Mesmo com limitações, tanto os participantes como as terapeutas da fala foram recetivos à tecnologia, destacando a importância de continuar a desenvolver e melhorar estes sistemas, com a sua participação e colaboração.

Ao longo da discussão de resultados, foram sugeridas várias melhorias e novas abordagens para aprimorar os resultados obtidos. A principal alteração a considerar deve focar-se no modelo de DL, dado que o desempenho do sistema depende diretamente da sua eficácia. Assim, seria pertinente construir uma base de dados maior e mais diversificada, incluindo os sinais adquiridos neste trabalho e aplicar métodos de *labelling* automático em vez de manual, para evitar possíveis erros. Além disso, seria útil investigar outras arquiteturas de modelos, treinar os modelos durante um maior número de *epochs* e testar os métodos descritos na Secção 2.4.3 que permitiriam evoluir para sistemas cada vez mais aprimorados para o seu utilizador. Também é essencial explorar a possibilidade de utilizar vários sensores EMG em simultâneo e novas formas de determinar o momento ideal para enviar o comando de controlo, uma vez que o algoritmo atual requer que a ação seja terminada e mantida por um tempo mínimo pré-estabelecido, o que aumenta a taxa de erro e limita a generalização do sistema. Adotando uma nova metodologia, seria possível explorar padrões de ativação, como um Clique Duplo.

É importante referir que foi identificado um erro de implementação no registo do tempo em que ocorre a primeira classificação "1" de um clique, introduzindo imprecisão nos valores de tempo de decisão e de intenção-decisão. Quanto ao design da interface, numa aplicação final, algumas configurações como *buffer size*, *duration*, *moving average* e *sampling rate* não devem ser alteráveis, pois não são relevantes para o utilizador. É essencial também garantir a rapidez de resposta da interface, evitando bloqueios.

Concluindo, este trabalho destaca a relevância de continuar a investir no desenvolvimento de interfaces homem-computador baseadas em inteligência artificial para melhorar a comunicação de doentes com ELA. A aplicação clínica desta tecnologia tem o potencial de prolongar significativamente a autonomia dos pacientes, permitindo-lhes manter a capacidade de se expressarem por mais tempo e, assim, melhorar a sua qualidade de vida. A colaboração contínua com os utilizadores finais e profissionais de saúde é essencial para refinar estas soluções, tornando-as cada vez mais eficazes e adaptadas às necessidades específicas de cada pessoa com ELA.

BIBLIOGRAFIA

- [1] J. M. Lourenço, *The NOVAthesis L^AT_EX Template User's Manual*, NOVA University Lisbon, 2021. URL: <https://github.com/joaomlourenco/novathesis/raw/main/template.pdf> (ver p. i).
- [2] A. Londral, «Assistive Technologies for Communication Empower Patients With ALS to Generate and Self-Report Health Data,» *Frontiers in Neurology*, vol. 13, 2022-04, ISSN: 1664-2295. DOI: [10.3389/fneur.2022.867567](https://doi.org/10.3389/fneur.2022.867567). URL: <https://www.frontiersin.org/journals/neurology/articles/10.3389/fneur.2022.867567> (ver p. 1).
- [3] Y. E. Choonara et al., «Trends in the Molecular Pathogenesis and Clinical Therapeutics of Common Neurodegenerative Disorders,» *International Journal of Molecular Sciences*, vol. 10, n.º 6, pp. 2510–2557, 2009, ISSN: 14220067. DOI: [10.3390/ijms10062510](https://doi.org/10.3390/ijms10062510). URL: <https://www.mdpi.com/1422-0067/10/6/2510> (ver pp. 1, 4).
- [4] P. Encarnação, L. Azevedo e A. R. Londral, *Tecnologias de apoio para pessoas com deficiência*, 1ª ed., Fundação para a Ciência e a Tecnologia (FCT) Departamento da Sociedade de Informação Unidade ACESSO, ed. Lisboa, 2015, ISBN: 978-972-667-345-3. URL: <https://www.acessibilidade.gov.pt/livros/tapd/html/index.html> (ver pp. 1, 5–7).
- [5] A. Londral, A. Pinto, S. Pinto, L. Azevedo e M. De Carvalho, «Quality of life in amyotrophic lateral sclerosis patients and caregivers: Impact of assistive communication from early stages,» *Muscle and Nerve*, vol. 52, n.º 6, pp. 933–941, 2015. DOI: <https://doi.org/10.1002/mus.24659>. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/mus.24659> (ver p. 1).
- [6] A. Londral, P. Encarnação e L. Azevedo, «Selecting AAC Devices for Persons with ALS Taking into Consideration the Disease Progression,» em *Assistive Technology Research Series*, vol. 25, 2009-08. DOI: [10.3233/978-1-60750-042-1-12](https://doi.org/10.3233/978-1-60750-042-1-12) (ver p. 2).
- [7] G. Staude e W. Wolf, «Objective motor response onset detection in surface myoelectric signals,» *Medical Engineering & Physics*, vol. 21, pp. 449–467, 1999, ISSN: 1350-4533.

- DOI: [https://doi.org/10.1016/S1350-4533\(99\)00067-3](https://doi.org/10.1016/S1350-4533(99)00067-3). URL: <https://www.sciencedirect.com/science/article/pii/S1350453399000673> (ver pp. 2, 12).
- [8] C. R. Carvalho, J. M. Fernández, A. J. del-Ama, F. Oliveira Barroso e J. C. Moreno, «Review of electromyography onset detection methods for real-time control of robotic exoskeletons,» *Journal of NeuroEngineering and Rehabilitation*, vol. 20, n.º 1, 2023-12, ISSN: 17430003. DOI: [10.1186/s12984-023-01268-8](https://doi.org/10.1186/s12984-023-01268-8) (ver pp. 2, 11, 12).
- [9] R. N. Lamptey, B. Chaulagain, R. Trivedi, A. Gothwal, B. Layek e J. Singh, «A Review of the Common Neurodegenerative Disorders: Current Therapeutic Approaches and the Potential Role of Nanotherapeutics,» *International Journal of Molecular Sciences*, vol. 23, n.º 3, p. 1, 2022, ISSN: 14220067. DOI: [10.3390/ijms23031851](https://doi.org/10.3390/ijms23031851). URL: <https://www.mdpi.com/1422-0067/23/3/1851> (ver p. 4).
- [10] A. D. Halli-Tierney, J. Luker e D. G. Carroll, «Parkinson Disease,» *American Family Physician*, vol. 102, n.º 11, pp. 679–691, 2020-12, ISSN: 1532-0650. URL: <https://pubmed.ncbi.nlm.nih.gov/33252908/> (ver p. 4).
- [11] R. A. Roos, «Huntington’s disease: A clinical review,» *Orphanet Journal of Rare Diseases*, vol. 5, p. 40, 2010-12, ISSN: 1750-1172. DOI: [10.1186/1750-1172-5-40](https://doi.org/10.1186/1750-1172-5-40) (ver p. 4).
- [12] J. Riancho, I. Gonzalo, M. Ruiz-Soto e J. Berciano, «Why do motor neurons degenerate? Actualisation in the pathogenesis of amyotrophic lateral sclerosis,» *Neurología (English Edition)*, vol. 34, n.º 1, pp. 27–37, 2019, ISSN: 2173-5808. DOI: <https://doi.org/10.1016/j.nrleng.2015.12.019>. URL: <https://www.sciencedirect.com/science/article/pii/S2173580817301633> (ver pp. 4, 5).
- [13] M. A. van Es et al., «Amyotrophic lateral sclerosis,» *The Lancet*, vol. 390, n.º 10107, pp. 2084–2098, 2017-11, ISSN: 0140-6736. DOI: [10.1016/S0140-6736\(17\)31287-4](https://doi.org/10.1016/S0140-6736(17)31287-4). URL: <https://www.sciencedirect.com/science/article/pii/S0140673617312874> (ver pp. 4, 5).
- [14] L. C. Zayia e P. Tadi, «Neuroanatomy, Motor Neuron,» em *StatPearls*, Atualiz. 24 jul 2023, StatPearls Publishing, 2023. URL: <https://www.ncbi.nlm.nih.gov/books/NBK554616/> (ver p. 5).
- [15] E. Diaz e H. Morales, «Spinal Cord Anatomy and Clinical Syndromes,» *Seminars in Ultrasound, CT and MRI*, vol. 37, n.º 5, pp. 360–371, 2016, ISSN: 0887-2171. DOI: [10.1053/j.sult.2016.05.002](https://doi.org/10.1053/j.sult.2016.05.002). URL: <https://www.sciencedirect.com/science/article/pii/S088721711630021X> (ver p. 5).
- [16] M. de Carvalho e M. Swash, «Lower motor neuron dysfunction in ALS,» *Clinical Neurophysiology*, vol. 127, n.º 7, pp. 2670–2681, 2016, ISSN: 1388-2457. DOI: [10.1016/j.clinph.2016.03.024](https://doi.org/10.1016/j.clinph.2016.03.024). URL: <https://www.sciencedirect.com/science/article/pii/S1388245716300062> (ver p. 5).

- [17] S. A. Goutman et al., «Recent advances in the diagnosis and prognosis of amyotrophic lateral sclerosis,» *The Lancet Neurology*, vol. 21, n.º 5, pp. 480–493, 2022, ISSN: 1474-4465. DOI: [10.1016/S1474-4422\(21\)00465-8](https://doi.org/10.1016/S1474-4422(21)00465-8) (ver p. 5).
- [18] P. Masrori e P. Van Damme, «Amyotrophic lateral sclerosis: a clinical review,» *European Journal of Neurology*, vol. 27, n.º 10, pp. 1918–1929, 2020, ISSN: 1468-1331. DOI: [10.1111/ene.14393](https://doi.org/10.1111/ene.14393) (ver pp. 5, 8).
- [19] B. J. Traynor, M. B. Codd, B. Corr, C. Forde, E. Frost e O. M. Hardiman, «Clinical Features of Amyotrophic Lateral Sclerosis According to the El Escorial and Airlie House Diagnostic Criteria: A Population-Based Study,» *Archives of Neurology*, vol. 57, n.º 8, pp. 1171–1176, 2000-08, ISSN: 0003-9942. DOI: [10.1001/archneur.57.8.1171](https://doi.org/10.1001/archneur.57.8.1171). URL: <https://doi.org/10.1001/archneur.57.8.1171> (ver p. 5).
- [20] J. M. Cedarbaum, N. Stambler, E. Malta, C. Fuller e D. Hilt, «The ALSFRS-R: a revised ALS functional rating scale that incorporates assessments of respiratory function,» *Journal of the Neurological Sciences*, vol. 169, n.º 1, pp. 13–21, 1999, ISSN: 0022-510X. DOI: [10.1016/S0022-510X\(99\)00210-5](https://doi.org/10.1016/S0022-510X(99)00210-5) (ver p. 5).
- [21] O. A. Khairoalsindi e A. R. Abuzinadah, «Maximizing the Survival of Amyotrophic Lateral Sclerosis Patients: Current Perspectives.,» *Neurology research international*, vol. 2018, p. 6534150, 2018, ISSN: 2090-1852. DOI: [10.1155/2018/6534150](https://doi.org/10.1155/2018/6534150) (ver p. 5).
- [22] G. Logroscino, R. Tortelli, G. Rizzo, B. Marin, P. M. Preux e A. Malaspina, «Amyotrophic lateral sclerosis: An Aging-Related Disease,» *Current Geriatrics Reports*, vol. 4, n.º 2, pp. 142–153, 2015, ISSN: 2196-7865. DOI: [10.1007/s13670-015-0127-8](https://doi.org/10.1007/s13670-015-0127-8) (ver p. 5).
- [23] B. Marin et al., «Age-specific ALS incidence: a dose–response meta-analysis,» *European Journal of Epidemiology*, vol. 33, n.º 7, pp. 621–634, 2018, ISSN: 1573-7284. DOI: [10.1007/s10654-018-0392-x](https://doi.org/10.1007/s10654-018-0392-x) (ver p. 5).
- [24] E. Kaniusas, *Biomedical Signals and Sensor I: Linking physiological phenomena and biosignals*. Springer Science & Business Media, 2012, pp. 1–18, ISBN: 978-3-642-24842-9. DOI: [10.1007/978-3-642-24843-6](https://doi.org/10.1007/978-3-642-24843-6). URL: <https://books.google.pt/books?id=mht54dnjV5wC&lpg=PA1&hl=pt-PT&pg=PA1#v=onepage&q&f=false> (ver p. 7).
- [25] M. B. Reaz, M. S. Hussain e F. Mohd-Yasin, «Techniques of EMG signal analysis: detection, processing, classification and applications,» *Biological Procedures Online*, vol. 8, n.º 1, p. 11, 2006, ISSN: 1480-9222. DOI: [10.1251/BP0115](https://doi.org/10.1251/BP0115) (ver pp. 7, 8).
- [26] D. Stashuk, «EMG signal decomposition: how can it be accomplished and used?» *Journal of Electromyography and Kinesiology*, vol. 11, n.º 3, pp. 151–173, 2001, ISSN: 1050-6411. DOI: [https://doi.org/10.1016/S1050-6411\(00\)00050-X](https://doi.org/10.1016/S1050-6411(00)00050-X). URL: <https://www.sciencedirect.com/science/article/pii/S105064110000050X> (ver p. 7).

- [27] L. McManus, G. De Vito e M. M. Lowery, «Analysis and Biophysics of Surface EMG for Physiotherapists and Kinesiologists: Toward a Common Language With Rehabilitation Engineers,» *Frontiers in Neurology*, vol. 11, 2020, ISSN: 1664-2295. DOI: [10.3389/fneur.2020.576729](https://doi.org/10.3389/fneur.2020.576729). URL: <https://www.frontiersin.org/journals/neurology/articles/10.3389/fneur.2020.576729> (ver pp. 8, 38).
- [28] I. H. Sarker, «Machine Learning: Algorithms, Real-World Applications and Research Directions,» *SN Computer Science*, vol. 2, n.º 3, p. 160, 2021, ISSN: 2661-8907. DOI: [10.1007/s42979-021-00592-x](https://doi.org/10.1007/s42979-021-00592-x) (ver p. 8).
- [29] C. Janiesch, P. Zschech e K. Heinrich, «Machine learning and deep learning,» vol. 31, n.º 3, pp. 685–695, 2021, ISSN: 1422-8890. DOI: [10.1007/s12525-021-00475-2](https://doi.org/10.1007/s12525-021-00475-2). URL: <https://doi.org/10.1007/s12525-021-00475-2> (ver pp. 8, 9).
- [30] A. Phinyomark e E. Scheme, «EMG Pattern Recognition in the Era of Big Data and Deep Learning,» *Big Data and Cognitive Computing*, vol. 2, n.º 3, pp. 1–27, 2018-09, ISSN: 2504-2289. DOI: [10.3390/bdcc2030021](https://doi.org/10.3390/bdcc2030021). URL: <https://www.mdpi.com/2504-2289/2/3/21> (ver p. 8).
- [31] A. Gerón, *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 2ª ed., N. Tache, ed. O'Reilly Media, Inc., 2019-06, ISBN: 978-1-492-03264-9 (ver pp. 8, 10).
- [32] I. H. Sarker, «Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions,» *SN Computer Science*, vol. 2, n.º 6, p. 420, 2021, ISSN: 2661-8907. DOI: [10.1007/s42979-021-00815-1](https://doi.org/10.1007/s42979-021-00815-1) (ver pp. 8, 9).
- [33] E. Velásquez, J. Cornelis, L. Omelina e B. Jansen, «Muscle Classification Via Hybrid CNN-LSTM Architecture from Surface EMG Signals,» em *2023 24th International Conference on Digital Signal Processing (DSP)*, 2023, pp. 1–5. DOI: [10.1109/DSP58604.2023.10167918](https://doi.org/10.1109/DSP58604.2023.10167918) (ver pp. 9, 14).
- [34] M. H. Mohd Noor, S. Y. Tan e M. N. Ab Wahab, «Deep Temporal Conv-LSTM for Activity Recognition,» *Neural Processing Letters*, vol. 54, n.º 5, pp. 4027–4049, 2022, ISSN: 1573-773X. DOI: [10.1007/s11063-022-10799-5](https://doi.org/10.1007/s11063-022-10799-5) (ver pp. 9, 13).
- [35] Y. Lecun, Y. Bengio e G. Hinton, «Deep learning,» *Nature*, vol. 521, n.º 7553, pp. 436–444, 2015, ISSN: 1476-4687. DOI: [10.1038/nature14539](https://doi.org/10.1038/nature14539) (ver p. 9).
- [36] N. K. Chauhan e K. Singh, «A Review on Conventional Machine Learning vs Deep Learning,» em *2018 International Conference on Computing, Power and Communication Technologies (GUCON)*, 2018, pp. 347–352. DOI: [10.1109/GUCON.2018.8675097](https://doi.org/10.1109/GUCON.2018.8675097) (ver p. 9).
- [37] S. R. Dubey, S. K. Singh e B. B. Chaudhuri, «Activation functions in deep learning: A comprehensive survey and benchmark,» *Neurocomputing*, vol. 503, pp. 92–108, 2022, ISSN: 0925-2312. DOI: [10.1016/j.neucom.2022.06.111](https://doi.org/10.1016/j.neucom.2022.06.111). URL: <https://www.sciencedirect.com/science/article/pii/S0925231222008426> (ver pp. 9, 10).

- [38] C. Nwankpa, W. Ijomah, A. Gachagan e S. Marshall, «Activation Functions: Comparison of trends in Practice and Research for Deep Learning,» *arXiv*, 2018-11. URL: <http://arxiv.org/abs/1811.03378> (ver pp. 9, 10).
- [39] H. Me S. M.N, «A Review on Evaluation Metrics for Data Classification Evaluations,» *International Journal of Data Mining & Knowledge Management Process*, vol. 5, n.º 2, pp. 01–11, 2015-03. DOI: [10.5121/ijdkp.2015.5201](https://doi.org/10.5121/ijdkp.2015.5201) (ver p. 10).
- [40] E. Mosqueira-Rey, E. Hernández-Pereira, D. Alonso-Ríos, J. Bobes-Bascarán e Á. Fernández-Leal, «Human-in-the-loop machine learning: a state of the art,» *Artificial Intelligence Review*, vol. 56, n.º 4, pp. 3005–3054, 2023, ISSN: 1573-7462. DOI: [10.1007/s10462-022-10246-w](https://doi.org/10.1007/s10462-022-10246-w) (ver p. 10).
- [41] A. Londral, N. Filipa, M. Nunes e M. De Carvalho, «A wireless user-computer interface to explore various sources of biosignals and visual biofeedback for severe motor impairment,» *Journal of Accessibility and Design for All*, 2013. DOI: [10.17411/jaces.v3i2.15](https://doi.org/10.17411/jaces.v3i2.15). URL: <https://www.researchgate.net/publication/271828242> (ver p. 11).
- [42] F. Di Nardo, A. Nocera, A. Cucchiarelli, S. Fioretti e C. Morbidoni, «Machine Learning for Detection of Muscular Activity from Surface EMG Signals,» *Sensors*, vol. 22, n.º 9, 2022, ISSN: 1424-8220. DOI: [10.3390/s22093393](https://doi.org/10.3390/s22093393) (ver p. 12).
- [43] M. Ghislieri, G. L. Cerone, M. Knaflitz e V. Agostini, «Long short-term memory (LSTM) recurrent neural network for muscle activity detection,» *Journal of NeuroEngineering and Rehabilitation*, vol. 18, n.º 1, 2021, ISSN: 1743-0003. DOI: [10.1186/s12984-021-00945-w](https://doi.org/10.1186/s12984-021-00945-w) (ver p. 13).
- [44] T. Schultz e A. Maedche, «Biosignals meet Adaptive Systems,» *SN Applied Sciences*, vol. 5, n.º 9, p. 234, 2023-09, ISSN: 2523-3971. DOI: [10.1007/s42452-023-05412-w](https://doi.org/10.1007/s42452-023-05412-w) (ver p. 15).
- [45] J. vom Brocke, A. Hevner e A. Maedche, «Introduction to Design Science Research,» em *Design Science Research. Cases*, J. vom Brocke, A. Hevner, A. Maedche e Springer, eds., Springer International Publishing, 2020, pp. 1–13, ISBN: 978-3-030-46781-4. DOI: [10.1007/978-3-030-46781-4_1](https://doi.org/10.1007/978-3-030-46781-4_1). URL: https://link.springer.com/chapter/10.1007/978-3-030-46781-4_1 (ver p. 16).
- [46] A. Londral et al., «Developing and validating high-value patient digital follow-up services: a pilot study in cardiac surgery,» *BMC Health Services Research*, vol. 22, n.º 1, p. 680, 2022, ISSN: 1472-6963. DOI: [10.1186/s12913-022-08073-4](https://doi.org/10.1186/s12913-022-08073-4) (ver p. 16).
- [47] D. Doroftei et al., «User-Centered Design,» em *Search and Rescue Robotics*, IntechOpen, 2017, cap. 2. DOI: [10.5772/intechopen.69483](https://doi.org/10.5772/intechopen.69483). URL: <http://www.intechopen.com/books/search-and-rescue-robotics-from-theory-to-practice/user-centered-design> (ver p. 16).

- [48] João Rodrigues, *JmdRodrigues/BioSoundScape*, URL: <https://github.com/JmdRodrigues/BioSoundScape>. Acedido em: 10 de março de 2024 (ver p. 17).
- [49] Python Software Foundation, *multiprocessing — Process-based parallelism, Python 3.12.4 documentation*, URL: <https://docs.python.org/3/library/multiprocessing.html> Acedido em: 10 de março de 2024 (ver p. 18).
- [50] PLUX Wireless Biosignals, *Python-samples: Python programming examples using PLUX's API*. URL: <https://github.com/pluxbiosignals/python-samples> Acedido em: 10 de março de 2024 (ver p. 18).
- [51] Qt for Python Team, *PySide2 · PyPI*, URL: <https://pypi.org/project/PySide2/>. Acedido em: 10 de março de 2024 (ver p. 18).
- [52] M. M. Santos, C. Quintão e H. Gamboa, *Study of the electromyographic signal dynamic behavior in Amyotrophic Lateral Sclerosis (ALS)*, tese de mestrado, 2014 (ver p. 19).
- [53] E. A. Chung e M. E. Benalcázar, «Real-Time Hand Gesture Recognition Model Using Deep Learning Techniques and EMG Signals,» 2019-09, pp. 1–5. DOI: [10.23919/EUSIPCO.2019.8903136](https://doi.org/10.23919/EUSIPCO.2019.8903136) (ver p. 20).
- [54] S. Abbaspour, A. Naber, M. Ortiz-catalan, H. Gholamhosseini e M. Lindén, «Real-time and Offline Evaluation of Myoelectric Pattern Recognition for the Decoding of Hand Movements,» *Sensors*, vol. 21, n.º 16, 2021, ISSN: 1424-8220. DOI: [10.3390/s21165677](https://doi.org/10.3390/s21165677) (ver p. 20).
- [55] Delsys®, *Technical Note 101: EMG Sensor Placement*. URL: www.delsys.com (ver p. 23).
- [56] Delsys®, *What factors affect EMG Signal Quality? – Signal Quality Monitor*, URL: <https://delsyseurope.com/emgworks/signal-quality-monitor/factors/>. Acedido em: 01 de agosto de 2024 (ver p. 25).
- [57] M. R. Turner, «Diagnosing ALS: the Gold Coast criteria and the role of EMG,» *Practical Neurology*, vol. 22, n.º 3, pp. 176–178, 2022, ISSN: 1474-7758. DOI: [10.1136/practneurol-2021-003256](https://doi.org/10.1136/practneurol-2021-003256). URL: <https://pn.bmj.com/content/22/3/176> (ver p. 31).
- [58] Delsys®, *Technical Note 103: EMG Signal Analysis*, 2022. URL: www.delsys.com (ver p. 32).
- [59] A. Phinyomark et al., «The Usefulness of Mean and Median Frequencies in Electromyography Analysis,» em *Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges*, IntechOpen, 2012-10, ISBN: 978-953-51-0805-4. DOI: [10.5772/50639](https://doi.org/10.5772/50639). URL: <https://www.intechopen.com/chapters/40123%20undefined/chapters/40123> (ver p. 36).

INFORMAÇÃO COMPLEMENTAR À METODOLOGIA

Este apêndice providencia informação complementar ao Capítulo 4. A Secção A.1 começa por apresentar as equações detalhadas para as Métricas de Avaliação implementadas no estudo. Na Secção A.2 encontra-se a tabela de informação demográfica dos participantes da sessão de teste da Segunda Iteração. Por fim e de igual forma a Secção A.3 fornece a informação demográfica tanto dos participantes sem e com patologia associada que estiveram presentes nas Sessões de Teste da Terceira Iteração.

A.1 Métricas de Avaliação

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN} \quad (A.1)$$

$$Sensibilidade = \frac{VP}{VP + FN} \quad (A.2)$$

$$Precisão = \frac{VP}{VP + FP} \quad (A.3)$$

$$Especificidade = \frac{VN}{VN + FP} \quad (A.4)$$

$$F1-Score = \frac{2 \times Precisão \times Sensibilidade}{Precisão + Sensibilidade} \quad (A.5)$$

A.2 Sessão de Teste da Segunda Iteração

Tabela A.1: Informação Demográfica dos participantes saudáveis da Sessão de Teste em Tempo Real da Segunda Iteração do Protótipo Inteligente da Aplicação.

Participante	Código Identificação ¹	Idade	Sexo ²	Altura (m)	Peso (kg)
1	H_A	54	F	1,70	65
2	H_B	55	M	1,70	71
3	H_C	78	M	1,80	80
4	H_D	77	F	1,60	72
5	H_E	47	M	1,83	93
6	H_F	41	F	1,69	62
7	H_G	27	M	1,80	90

¹ O prefixo "H_" identifica o sujeito saudável, do inglês *Healthy*.

² "F"denomina feminino e "M"denomina masculino.

A.3 Sessão de Teste da Terceira Iteração

Tabela A.2: Informação Demográfica dos participantes saudáveis da Sessão de Teste em Tempo Real da Terceira Iteração do Protótipo Inteligente da Aplicação.

Participante	Código Identificação ¹	Idade	Sexo ²	Altura (m)	Peso (kg)
1	H_H	22	F	1,67	64
2	H_I	22	F	1,67	58
3	H_J	21	M	1,84	76
4	H_K	22	M	1,85	72
5	H_L	22	F	1,67	58
6	H_M	22	M	1,85	69
7	H_N	22	F	1,67	50
8	H_O	22	F	1,60	55
9	H_P	22	M	1,72	75
10	H_Q	21	F	1,65	62
11	H_R	23	M	1,70	64
12	H_S	22	F	1,64	64
13	H_T	22	M	1,78	62
14	H_U	22	M	1,80	74
15	H_V	22	F	1,62	54
16	H_X	23	F	1,60	47
17	H_Z	23	F	1,63	52
18	H_AA	23	F	1,73	55,5
19	H_BB	22	F	1,70	80
20	H_CC	23	F	1,67	63
21	H_DD	21	F	1,57	51
22	H_EE	22	M	1,73	64
23	H_FF	22	F	1,58	60
24	H_GG	21	F	1,65	55
25	H_HH	22	M	1,87	84
26	H_II	21	F	1,75	59
27	H_JJ	22	F	1,59	44
28	H_KK	24	M	1,73	55
29	H_LL	29	F	1,63	50
30	H_MM	37	M	1,81	70
31	H_NN	27	F	1,69	70

¹ O prefixo "H_"identifica o sujeito saudável, do inglês *Healthy*.

² "F"denomina feminino e "M"denomina masculino.

Tabela A.3: Informação Demográfica dos participantes com ELA da Sessão de Teste em Tempo Real da Terceira Iteração do Protótipo Inteligente da Aplicação.

Participante	Código ¹	Idade	Sexo ²	Tipo de ELA	Idade do Diagnóstico	Pontuação na Escala ALSFRS-R
1	ALS_OO	46	M	Medular	44	13/48
2	ALS_PP	46	F	Bulbar	45	43/48
3	ALS_QQ	59	M	Mista	57	12/48
4	ALS_RR	46	F	Mista	45	12/48
5	ALS_SS	67	M	Respiratória	66	23/48
6	ALS_A6	66	M	Mista	65	-
7	ALS_TT	66	F	Primária	56	22/48
8	ALS_UU	48	M	Bulbar	45	16/48
9	ALS_VV	60	F	Primária	57	28/48
10	ALS_XX	74	F	Bulbar	73	-
11	ALS_ZZ	52	M	Bulbar	50	23/48
12	ALS_A1	46	M	Mista	43	35/48
13	ALS_A2	53	F	Medular	51	39/48
14	ALS_A3	55	M	Primária	33	-
15	ALS_A4	63	F	Mista	63	29/48
16	ALS_A5	60	F	Bulbar	59	27/48

¹ O prefixo "ALS_" identifica o sujeito com ELA, do inglês *Amyotrophic Lateral Sclerosis*.

² "F" denomina feminino e "M" denomina masculino.

RESULTADOS COMPLEMENTARES

Este apêndice providencia resultados complementares aos apresentados no Capítulo 5. Primeiramente, inclui imagens da interface desenvolvida durante a Primeira Iteração, cuja página inicial se manteve nas seguintes. De seguida, apresenta resultados associados ao desenvolvimento do modelo de DL, começando pela Secção B.2.1 que se debruça sobre a avaliação da quantidade de dados para cada classe variando o valor do tamanho da janela e *overlap* associado ao processo de segmentação em janelas. A subsecção seguinte demonstra detalhadamente as características dos modelos desenvolvidos com a respetiva *performance*. Adicionalmente, na Secção B.3 apresentam-se as tabelas com toda a informação detalhada acerca da análise desenvolvida aos sinais EMG adquiridos. Já na Subsecção B.4.1 encontram-se gráficos de barras com a agregação e descrição pormenorizada dos cliques detetados em comparação com o que foi realizado bem como os erros associados à identificação dos mesmos, organizados por participante. Por fim, a Subsecção B.4.2 possui imagens de sinais EMG de diferentes participantes saudáveis com identificação dos movimentos detetados, como forma de exemplos de outros casos além dos expostos na Subsecção 5.5.3.

B.1 Página Principal e de Visualização do sinal EMG desenvolvidas na Primeira Iteração

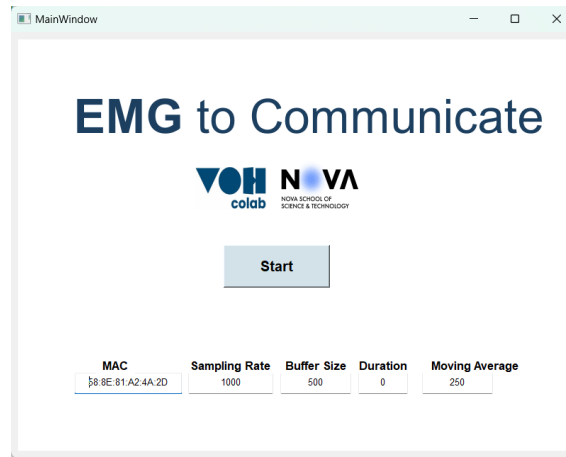
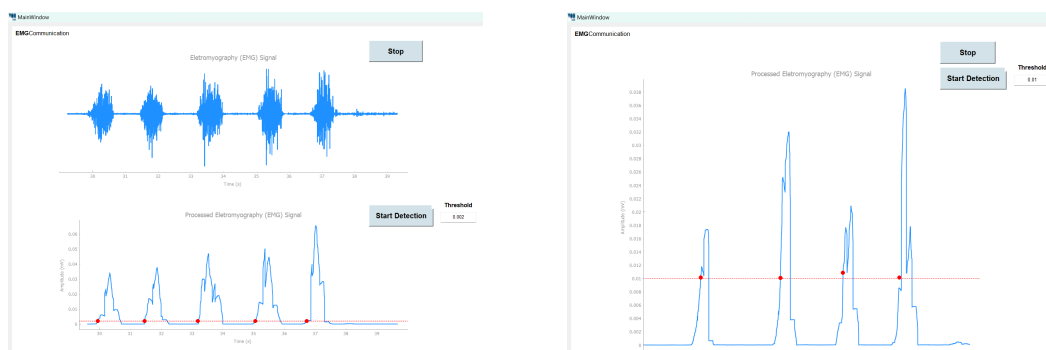


Figura B.1: Página Principal da Aplicação



(a) Gráfico do sinal EMG em bruto e processado

(b) Gráfico do sinal EMG processado

Figura B.2: Página de aquisição do sinal EMG com a deteção de ativação muscular por *threshold*. A figura da esquerda diz respeito à aplicação com a implementação de visualização de ambos os sinais, em bruto e processado, sendo que a da direita apresenta apenas o gráfico do sinal EMG processado.

B.2 Algoritmo de *Deep Learning*

B.2.1 Análise da Proporção de Dados para cada Classe com a Variação do Tamanho da Janela e Percentagem de *Overlap*

Tabela B.1: Proporção (%) entre a quantidade de janelas classificadas como *Rest*, *One_Click* e *Transition*, considerando diferentes valores de dimensão de janela e sobreposição

		Sobreposição entre janelas (%)								
		30			40			50		
Dimensão da janela (ms)	Label	R	OC	T	R	OC	T	R	OC	T
	100		41,0	54,7	4,2	41,1	54,7	4,2	41,1	54,7
150		40,0	53,6	6,4	40,0	53,6	6,4	40,0	53,6	6,4
200		38,9	52,6	8,5	38,9	52,6	8,5	38,9	52,6	8,5
250		37,8	51,5	10,6	37,8	51,5	10,6	37,9	51,5	10,6
300		36,7	50,4	12,9	36,8	50,4	12,8	36,8	50,4	12,8

B.2.2 Descrição dos Modelos Desenvolvidos e os Resultados obtidos

Tabela B.2: Descrição das características das diferentes camadas constituintes dos modelos de *Deep Learning* desenvolvidos

Camada Modelo	Conv1D			Conv1D			LSTM		Densa	
	Função Ativação	Tamanho do Kernel	Nº de Filtros	Função Ativação	Tamanho do Kernel	Nº de Filtros	Função Ativação	Nº de unidades	Função Ativação	Nº de neurónios
1	ReLU	3	64	ReLU	3	64	Tanh	128	ReLU	64
2	Tanh	4	96	Tanh	2	64	Tanh	32	ReLU	64
3	ReLU	2	32	Tanh	5	32	Tanh	128	Tanh	128
4	ReLU	2	32	Tanh	5	32	Tanh	128	Tanh	128
5	ReLU	2	32	Tanh	5	32	Tanh	128	Tanh	128
6	ReLU	2	32	ReLU	2	32	Tanh	96	Tanh	128

Tabela B.3: Resultados obtidos no conjunto de teste para os diferentes modelos

Resultados Modelo	<i>Accuracy</i> (%)	Precisão (%)	Sensibilidade (%)	<i>F1-Score</i> (%)	Especificidade (%)
1	88,6	92,3	87,8	90,0	89,7
2	87,5	90,3	88,0	89,1	86,6
3	88,9	91,6	89,1	90,4	88,5
4	89,0	89,9	91,5	90,7	85,6
5	89,3	90,4	91,3	90,8	86,4
6	87,1	92,5	84,7	88,5	90,4

B.3 Análise em Frequência, Amplitude e Qualidade dos sinais EMG adquiridos durante os Testes da Terceira Iteração

Tabela B.4: Descrição em frequência, amplitude e qualidade dos sinais EMG adquiridos em participantes saudáveis. Na coluna "Músculo", "FUC"denomina Flexor Ulnar do Carpo e "M"denomina Masséter. As linhas destacadas correspondem a sinais que foram descartados para o estudo devido a problemas durante a aquisição.

Participante	Músculo	Amplitude Média (mV)	SNR (dB)	Frequência Mediana (Hz)	Frequência em que ocorre a potência máxima (Hz)	Potência Total (mV^2)	RMS (mV)	Duração aquisição (s)
H_H	FUC	$\mu = -0,018, \sigma = 0,049,$ Max=0,738, Min=-0,840	21,3	184,7	96,3	3,55E-03	5,22E-02	83,1
H_I	FUC	$\mu = -0,018, \sigma = 0,050,$ Max=0,528, Min=-0,772	23,0	145,1	84,5	4,45E-03	5,35E-02	81,9
H_J	FUC	$\mu = -0,018, \sigma = 0,137,$ Max=1,136, Min=-1,136	30,1	140,2	115,0	1,41E-02	1,38E-01	73,2
H_K	FUC	$\mu = -0,018, \sigma = 0,039,$ Max=0,720, Min=-0,712	20,7	135,3	47,8	2,74E-03	4,26E-02	77,6
H_L	FUC	$\mu = -0,018, \sigma = 0,055,$ Max=0,843, Min=-0,979	23,0	149,4	50,0	3,26E-03	5,78E-02	74,7
H_M	FUC	$\mu = -0,018, \sigma = 0,028,$ Max=0,285, Min=-0,399	17,0	150,5	90,5	5,26E-03	3,30E-02	80,7

Continua na próxima página

Participante	Músculo	Amplitude Média (mV)	SNR (dB)	Frequência Mediana (Hz)	Frequência em que ocorre a potência máxima (Hz)	Potência Total (mV^2)	RMS (mV)	Duração aquisição (s)
H_N	FUC	$\mu = -0,018, \sigma = 0,027,$ Max=0,366, Min=-0,452	17,2	164,4	50,0	3,77E-03	3,22E-02	114,5
H_O	FUC	$\mu = -0,018, \sigma = 0,041,$ Max=0,538, Min=-0,726	19,4	187,9	128,1	3,41E-03	4,51E-02	78,7
H_P	FUC	$\mu = -0,018, \sigma = 0,040,$ Max=1,136, Min=-1,136	19,4	144,8	98,3	1,21E-03	4,40E-02	108,4
H_Q	FUC	$\mu = -0,018, \sigma = 0,033,$ Max=0,452, Min=-0,715	20,7	131,9	79,5	2,29E-03	3,79E-02	77,3
H_R	FUC	$\mu = -0,018, \sigma = 0,059,$ Max=1,136, Min=-0,916	22,7	124,9	79,7	2,63E-03	6,19E-02	90,5
H_S	FUC	$\mu = -0,018, \sigma = 0,052,$ Max=1,057, Min=-0,859	21,1	145,3	50,0	2,30E-03	5,47E-02	88,5
H_T	FUC	$\mu = -0,018, \sigma = 0,081,$ Max=1,136, Min=-1,136	24,7	153,3	54,5	4,90E-03	8,27E-02	86,5
H_U	FUC	$\mu = -0,018, \sigma = 0,040,$ Max=0,596, Min=-1,038	21,4	145,2	100,5	1,57E-03	4,42E-02	79,6
H_V	FUC	$\mu = -0,018, \sigma = 0,033,$ Max=0,654, Min=-0,454	9,8	194,5	50,0	2,37E-03	3,73E-02	161,0
H_X	FUC	$\mu = -0,018, \sigma = 0,053,$ Max=0,460, Min=-0,935	23,4	137,0	77,3	3,37E-03	5,62E-02	83,0

Continua na próxima página

Participante	Músculo	Amplitude Média (mV)	SNR (dB)	Frequência Mediana (Hz)	Frequência em que ocorre a potência máxima (Hz)	Potência Total (mV^2)	RMS (mV)	Duração aquisição (s)
H_Z	FUC	$\mu = -0,018, \sigma = 0,037,$ Max=0,539, Min=-0,568	11,0	159,3	75,7	4,35E-03	4,09E-02	72,2
H_AA	FUC	$\mu = -0,018, \sigma = 0,055,$ Max=0,793, Min=-0,785	23,1	124,2	46,1	4,61E-03	5,79E-02	86,0
H_BB	FUC	$\mu = -0,018, \sigma = 0,028,$ Max=0,407, Min=-0,246	17,8	163,8	50,0	4,32E-03	3,32E-02	122,1
H_CC	FUC	$\mu = -0,018, \sigma = 0,035,$ Max=0,690, Min=-0,481	14,9	148,4	50,0	2,45E-03	3,94E-02	86,9
H_DD	FUC	$\mu = -0,018, \sigma = 0,044,$ Max=0,892, Min=-0,543	15,9	157,4	95,6	2,30E-03	4,73E-02	100,5
H_EE	FUC	$\mu = -0,018, \sigma = 0,030,$ Max=0,503, Min=-0,423	19,9	147,9	50,0	3,38E-03	3,52E-02	88,8
H_FF	FUC	$\mu = -0,018, \sigma = 0,033,$ Max=0,604, Min=-0,432	20,3	150,4	67,4	2,86E-03	3,78E-02	109,7
H_GG	FUC	$\mu = -0,018, \sigma = 0,034,$ Max=0,801, Min=-1,136	14,4	175,9	50,0	9,01E-04	3,81E-02	116,0
H_HH	FUC	$\mu = -0,018, \sigma = 0,052,$ Max=0,912, Min=-1,035	23,3	125,1	50,0	2,59E-03	5,47E-02	75,1
H_II	FUC	$\mu = -0,018, \sigma = 0,047,$ Max=0,503, Min=-0,750	24,2	129,1	75,0	4,14E-03	5,04E-02	73,4

Continua na próxima página

Participante	Músculo	Amplitude Média (mV)	SNR (dB)	Frequência Mediana (Hz)	Frequência em que ocorre a potência máxima (Hz)	Potência Total (mV^2)	RMS (mV)	Duração aquisição (s)
H_JJ	FUC	$\mu = -0,018, \sigma = 0,091,$ Max=1,136, Min=-1,136	20,8	152,7	102,4	6,18E-03	9,25E-02	81,2
H_KK	FUC	$\mu = -0,018, \sigma = 0,122,$ Max=1,136, Min=-1,136	32,2	123,6	59,5	1,11E-02	1,23E-01	79,0
H_LL	FUC	$\mu = -0,018, \sigma = 0,059,$ Max=0,937, Min=-0,753	20,5	151,7	74,9	3,81E-03	6,16E-02	77,3
H_MM	FUC	$\mu = -0,018, \sigma = 0,093,$ Max=1,136, Min=-1,136	24,8	101,7	78,8	6,54E-03	9,50E-02	88,3
H_NN	FUC	$\mu = -0,018, \sigma = 0,039,$ Max=0,501, Min=-0,664	20,7	134,1	61,1	3,73E-03	4,33E-02	106,9
H_I	M	$\mu = -0,018, \sigma = 0,023,$ Max=0,233, Min=-0,208	16,0	129,2	66,4	8,75E-03	2,96E-02	150,4
H_J	M	$\mu = -0,018, \sigma = 0,042,$ Max=0,753, Min=-0,620	24,8	108,7	59,7	2,92E-03	4,54E-02	73,8
H_P	M	$\mu = -0,018, \sigma = 0,024,$ Max=0,257, Min=-0,451	17,9	131,5	50,0	3,19E-03	3,04E-02	90,2
H_Q	M	$\mu = -0,018, \sigma = 0,037,$ Max=0,458, Min=-0,430	20,9	115,1	63,8	6,00E-03	4,11E-02	80,7
H_CC	M	$\mu = -0,018, \sigma = 0,029,$ Max=0,393, Min=-0,306	16,4	120,8	50,0	4,99E-03	3,42E-02	96,9

Continua na próxima página

Participante	Músculo	Amplitude Média (mV)	SNR (dB)	Frequência Mediana (Hz)	Frequência em que ocorre a potência máxima (Hz)	Potência Total (mV^2)	RMS (mV)	Duração aquisição (s)
H_DD	M	$\mu = -0,018, \sigma = 0,028,$ Max=0,239, Min=-0,234	12,1	105,9	50,0	1,17E-02	3,31E-02	84,8
H_EE	M	$\mu = -0,018, \sigma = 0,032,$ Max=0,281, Min=-0,412	18,2	153,0	50,0	6,77E-03	3,71E-02	83,2
H_FF	M	$\mu = -0,018, \sigma = 0,034,$ Max=0,319, Min=-0,316	18,2	151,1	50,0	1,04E-02	3,87E-02	73,3
H_GG	M	$\mu = -0,018, \sigma = 0,015,$ Max=0,129, Min=-0,148	11,7	119,3	86,7	9,98E-03	2,33E-02	90,0
H_HH	M	$\mu = -0,018, \sigma = 0,104,$ Max=0,805, Min=-0,790	8,1	116,3	50,0	1,60E-02	1,05E-01	66,7
H_II	M	$\mu = -0,018, \sigma = 0,043,$ Max=0,422, Min=-0,419	18,3	131,4	50,0	9,69E-03	4,69E-02	83,4
H_JJ	M	$\mu = -0,018, \sigma = 0,031,$ Max=0,220, Min=-0,372	16,6	135,6	98,1	7,51E-03	3,55E-02	70,8
H_KK	M	$\mu = -0,018, \sigma = 0,026,$ Max=0,269, Min=-0,303	12,0	116,9	37,4	8,55E-03	3,20E-02	106,7
H_LL	M	$\mu = -0,018, \sigma = 0,036,$ Max=0,296, Min=-0,331	16,5	123,0	74,6	1,33E-02	4,05E-02	83,2
H_MM	M	$\mu = -0,018, \sigma = 0,037,$ Max=0,367, Min=-0,545	20,5	121,7	69,1	5,04E-03	4,15E-02	77,1

Continua na próxima página

Participante	Músculo	Amplitude Média (mV)	SNR (dB)	Frequência Mediana (Hz)	Frequência em que ocorre a potência máxima (Hz)	Potência Total (mV^2)	RMS (mV)	Duração aquisição (s)
H_NN	M	$\mu = -0,018, \sigma = 0,040,$ Max=0,299, Min=-0,401	19,8	125,0	77,8	1,11E-02	4,42E-02	73,8

Tabela B.5: Descrição em frequência, amplitude e qualidade dos sinais EMG adquiridos em participantes com ELA. Na coluna "Músculo", "FUC"denomina Flexor Ulnar do Carpo, "M"denomina Masséter e "Q"corresponde a Quadríceps. A linha destacada corresponde a um sinal que foi descartado para o estudo devido a problemas durante a aquisição.


Participante	Músculo	Amplitude Média (mV)	SNR (dB)	Frequência Mediana (Hz)	Frequência em que ocorre a potência máxima (Hz)	Potência Total (mV^2)	RMS (mV)	Duração aquisição (s)
ALS_ZZ	FUC	$\mu = -0,018, \sigma = 0,015,$ Max=0,164, Min=-0,215	9,1	137,3	68,0	5,86E-03	2,35E-02	92,8
ALS_OO	M	$\mu = -0,018, \sigma = 0,025,$ Max=0,393, Min=-0,367	13,9	210,1	194,3	3,57E-03	3,05E-02	128,2
ALS_PP	M	$\mu = -0,018, \sigma = 0,029,$ Max=0,311, Min=-0,407	17,3	169,4	117,6	5,51E-03	3,40E-02	81,0
ALS_QQ	M	$\mu = -0,018, \sigma = 0,028,$ Max=0,250, Min=-0,267	16,7	197,6	165,8	1,10E-02	3,34E-02	126,5
ALS_RR	M	$\mu = -0,018, \sigma = 0,036,$ Max=0,288, Min=-0,303	11,5	222,4	200,3	1,36E-02	3,99E-02	86,1
ALS_SS	M	$\mu = -0,018, \sigma = 0,016,$ Max=0,126, Min=-0,177	9,0	150,0	56,7	9,75E-03	2,39E-02	93,2
ALS_TT	M	$\mu = -0,018, \sigma = 0,022,$ Max=0,146, Min=-0,175	11,6	124,7	49,9	1,74E-02	2,82E-02	83,0
ALS_UU	M	$\mu = -0,018, \sigma = 0,044,$ Max=0,392, Min=-0,396	21,7	166,8	116,6	1,13E-02	4,71E-02	81,2

Continua na próxima página


Participante	Músculo	Amplitude Média (mV)	SNR (dB)	Frequência Mediana (Hz)	Frequência em que ocorre a potência máxima (Hz)	Potência Total (mV^2)	RMS (mV)	Duração aquisição (s)
ALS_VV	M	$\mu = -0,018, \sigma = 0,012,$ Max=0,078, Min=-0,135	10,2	221,2	200,1	1,14E-02	2,19E-02	103,1
ALS_XX	M	$\mu = -0,018, \sigma = 0,051,$ Max=0,559, Min=-0,526	23,3	186,2	135,8	7,72E-03	5,38E-02	82,1
ALS_A1	M	$\mu = -0,018, \sigma = 0,033,$ Max=0,282, Min=-0,304	14,2	198,3	50,0	1,21E-02	3,76E-02	87,2
ALS_A2	M	$\mu = -0,018, \sigma = 0,008,$ Max=0,1, Min=-0,129	8,4	205,5	200,4	4,30E-03	1,96E-02	75,5
ALS_A3	M	$\mu = -0,018, \sigma = 0,067,$ Max=0,919, Min=-0,763	16,0	133,1	50,0	5,04E-03	6,89E-02	80,8
ALS_A4	M	$\mu = -0,018, \sigma = 0,018,$ Max=0,189, Min=-0,227	10,4	214,5	50,0	7,55E-03	2,56E-02	90,1
ALS_A5	M	$\mu = -0,018, \sigma = 0,022,$ Max=0,167, Min=-0,233	11,6	203,7	50,1	1,09E-02	2,88E-02	87,9
ALS_ZZ	Q	$\mu = -0,018, \sigma = 0,013,$ Max=0,111, Min=-0,170	14,4	97,2	39,0	7,79E-03	2,25E-02	98,0
ALS_A6	Q	$\mu = -0,018, \sigma = 0,01,$ Max=0,064, Min=-0,099	8,1	110,4	43,3	1,42E-02	2,05E-02	26,3

B.4 Algoritmo de Detecção de Padrões de Ativação Muscular


B.4.1 Gráficos de Barra com Agregação e Descrição dos Resultados da Detecção em Tempo Real




(a) Tarefa 1 (Clique Curto)- Número de vezes realizado vs detetado



(b) Tarefa 2 (Clique Longo)- Número de vezes realizado vs detetado




(c) Tarefa 1 (Clique Curto) - Falsos Negativos




(d) Tarefa 2 (Clique Longo) - Falsos Negativos

Figura B.3: Comparação do desempenho do Algoritmo de Classificação de Padrões de Ativação Muscular entre a Tarefa 1 e 2 no conjunto de 21 participantes saudáveis para os quais se verificaram falhas na detecção.


APÊNDICE B. RESULTADOS COMPLEMENTARES




(a) Tarefa 1 (Clique Curto)- Número de vezes realizado vs detetado



(b) Tarefa 2 (Clique Longo)- Número de vezes realizado vs detetado



(c) Tarefa 1 (Clique Curto) - Falsos Negativos



(d) Tarefa 2 (Clique Longo) - Falsos Negativos

Figura B.4: Comparação do desempenho do Algoritmo de Classificação de Padrões de Ativação Muscular entre a Tarefa 1 e 2 no conjunto de 13 participantes com ELA para os quais se verificaram falhas na detecção.

B.4.2 Exemplos de Sinais EMG com Detecção de Falsos Negativos

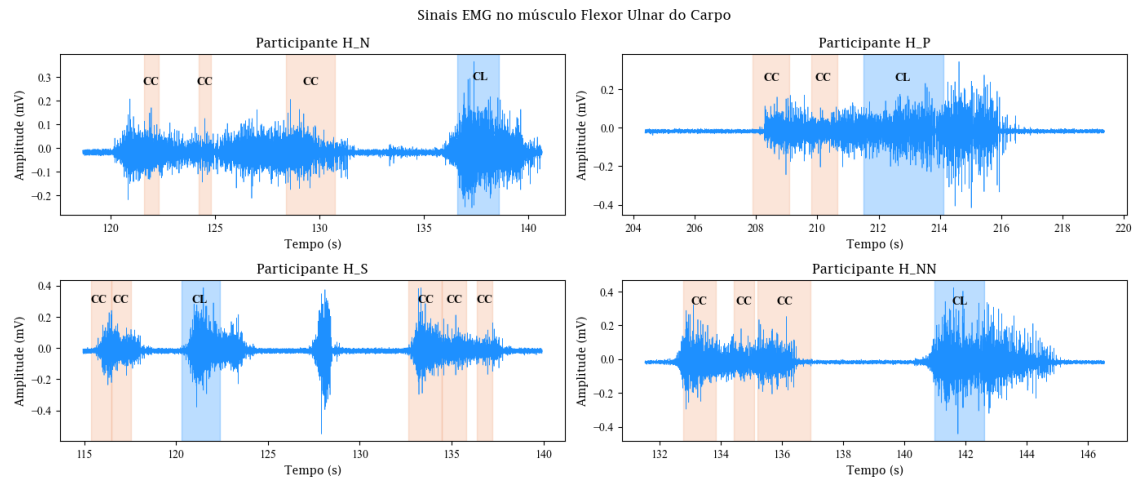


Figura B.5: Exemplos de sinais de 4 participantes saudáveis para os quais ocorreram Falsos Negativos identificados.

TRABALHO COMPLEMENTAR

Este anexo inclui o resumo submetido para o 1º Fórum de Inovação em Medicina e Engenharia Biomédica, promovido pela Sociedade de Ciências Médicas de Lisboa. O trabalho, que foi aceite para apresentação oral, abordou a metodologia, os resultados e as conclusões desta dissertação de Mestrado, tendo sido distinguido com o Prémio “Sociedade de Ciências Médicas de Lisboa” pela Melhor Comunicação Oral na Mesa 1 – Inteligência Artificial na Tomada de Decisões Clínicas.

Interface Inteligente baseada em Eletromiografia para melhorar a capacidade de comunicação em Pessoas com Doenças Neurodegenerativas

Catarina Consolado ^a, Cláudia Quarema ^{a,b}, Ana Rita Londral ^{a,c}

^a Departamento de Física, NOVA School of Sciences and Technology, NOVA University Lisbon, 2829-516 Caparica, Portugal

^b LIBPhys—UNL, Laboratory for Instrumentation, Biomechanical Engineering and Radiation Physics, Faculty of Sciences and Technology, NOVA University Lisbon, 2829-516 Caparica, Portugal

^c Comprehensive Health Research Center (CHRC), NOVA Medical School, NOVA University of Lisbon, Lisbon, Portugal

As doenças neurodegenerativas, como a Esclerose Lateral Amiotrófica (ELA), resultam na perda da fala e função motora, tornando essenciais as tecnologias de apoio à comunicação. Com o avanço da doença e as progressivas dificuldades motoras, é crucial desenvolver interfaces inteligentes e adaptáveis. A utilização de Inteligência Artificial para a deteção de movimentos voluntários através de sinais eletromiográficos (EMG) tem o potencial de adaptar-se às capacidades motoras do doente, permitindo que este mantenha a capacidade de comunicar. O objetivo deste trabalho foi realizar as etapas iniciais necessárias ao desenvolvimento de uma aplicação inteligente que deteta em tempo real contrações musculares voluntárias, traduzindo-as em comandos de controlo do computador.

Primeiro, foi desenvolvida a aplicação para aquisição e visualização em tempo real do sinal EMG. Foi implementado um modelo de *Deep Learning* (DL), combinando uma *Convolutional Neural Network* e *Long-Short Term Memory*, treinado com sinais EMG de indivíduos sem patologia associada, para classificar janelas de sinal em contração ou repouso. Para o controlo do computador, foi criado um algoritmo para detetar padrões nas previsões do modelo de DL, permitindo dois comandos distintos: clique curto (contração curta seguida de repouso) e clique longo (contração prolongada).

Para testar a interface em tempo real, foram realizados testes com 31 indivíduos sem patologia associada, recolhendo 31 sinais no flexor ulnar do carpo e 16 no músculo masséter. Atualmente, estão a ser realizados testes em participantes com ELA, em parceria com a Associação Portuguesa de Esclerose Lateral Amiotrófica.

Durante a fase de treino e teste do modelo, obteve-se uma *accuracy* offline de 88,6% e nos testes com indivíduos saudáveis de 90,5%. A análise comparativa entre os eventos online e os detetados no sinal EMG revelou uma sensibilidade de 91,9% para cliques curtos e 75,3% para cliques longos. A análise da experiência do utilizador mostrou maior dificuldade em manter a contração, sendo o clique curto intuitivo e fácil de realizar.

Concluindo, os resultados indicam que uma interface inteligente controlada por eletromiografia é viável para tecnologias de apoio à comunicação. A introdução do modelo de DL é uma inovação crucial, garantindo um melhor desempenho no controlo e interação com os sistemas de comunicação. A análise dos resultados dos testes em indivíduos com ELA será essencial para validar a eficácia e viabilidade desta solução.

Palavras-chave: Tecnologias de apoio para a comunicação, Inteligência Artificial, Interface Homem-Computador, Deteção de contrações musculares, Doenças Neurodegenerativas.



2024

Desenvolvimento de uma Interface Homem-Computador para a Identificação em Tempo Real e Inteligente de Contrações Voluntárias no Sinal Eletromiográfico aplicado a Pessoas com Doenças Neurodegenerativas

Catarina Consolado



NOVA SCHOOL OF
SCIENCE & TECHNOLOGY