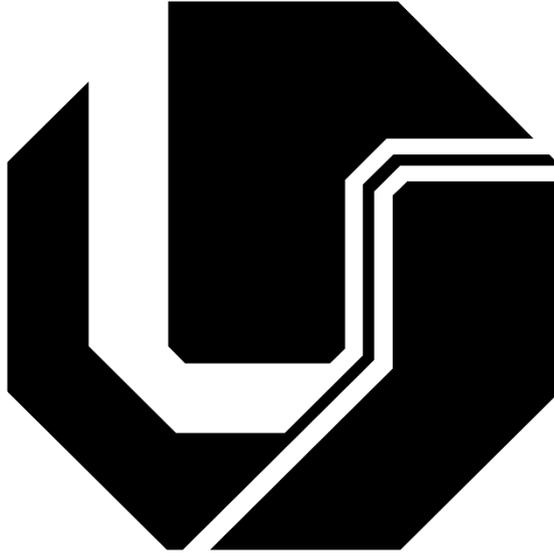


UNIVERSIDADE FEDERAL DE UBERLÂNDIA

LUCIANO BRINCK PERES



**CLASSIFICAÇÃO DE ATIVIDADE ELETROMIOGRÁFIA FACIAL DE INDIVÍDUOS
SAUDÁVEIS E COM HANSENÍASE POR MEIO DE MÁQUINA DE VETORES DE
SUPORTE**

Uberlândia
2016

LUCIANO BRINCK PERES

CLASSIFICAÇÃO DE ATIVIDADE ELETROMIOGRÁFIA FACIAL DE INDIVÍDUOS SAUDÁVEIS E COM HANSENÍASE POR MEIO DE MÁQUINA DE VETORES DE SUPORTE

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, como requisito parcial à obtenção do título de Mestre em Ciências.
Área de concentração: Engenharia Biomédica

Uberlândia, 16 de agosto de 2016.

Banca Examinadora

Prof. Dr. Adriano de Oliveira Andrade – UFU (Orientador)

Prof. Dr. Adriano Alves Pereira– UFU

Profa. Dra. Isabela Maria Bernardes Goulart – UFU

Prof. Dr. Cesar Ferreira Amorim - UNICID

Prof. Dr. Adriano de Oliveira Andrade

Orientador

Prof. Dr. Edgard Afonso Lamounier Junior

Coordenador do curso de Pós-Graduação

LUCIANO BRINCK PERES

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

P437c Peres, Luciano Brinck, 1990-
2016 Classificação de atividade eletromiográfica facial de indivíduos saudáveis e com hanseníase por meio de máquina de vetores de suporte / Luciano Brinck Peres. - 2016.
66 f. : il.

Orientador: Adriano de Oliveira Andrade.
Dissertação (mestrado) - Universidade Federal de Uberlândia, Programa de Pós-Graduação em Engenharia Biomédica.
Inclui bibliografia.

1. Engenharia biomédica - Teses. 2. Aprendizado do computador - Teses. 3. Hanseníase - Teses. 4. Eletromiografia - Teses. I. Andrade, Adriano de Oliveira. II. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Engenharia Biomédica. III. Título.

CDU: 62:61

Classificação de atividade eletromiográfica facial de indivíduos saudáveis e com hanseníase por meio de máquina de vetores de suporte

Banca Examinadora

Prof. Dr. Adriano de Oliveira Andrade – UFU (Orientador)

Prof. Dr. Adriano Alves Pereira – UFU

Profa. Dra. Izabela Maria Bernardes Goulart – UFU

Prof. Dr. Cesar Ferreira Amorim - UNICID

Dedicatória

“E tudo quanto fizerdes, fazei-o de coração, como ao Senhor, e não aos homens, sabendo que do Senhor recebereis como recompensa a herança; servi a Cristo o SENHOR...”
Colossenses 3.24-25. Dedico este trabalho a meu Deus e a meu querido pai. Pai, todas as minhas conquistas são na verdade suas conquistas. O senhor tornou tudo isso possível por isso dedico ao senhor a minha dissertação.

Agradecimentos

É comum alunos de pós-graduação se preocuparem com o dia da defesa, ficarem nervosos, ansiosos e com medo. Agradeço a Deus pela vida do meu orientador Adriano de Oliveira Andrade. Graças a ele, eu não tenho esses medos. Uma frase que marcou muito esse tijolo que coloco na parede da minha vida é “as coisas vão acontecer na hora que devem acontecer”. Obrigado Adriano, por sua paciência, dedicação, conselhos e orientação.

Agradeço a meus pais que depositaram em mim sua confiança e acreditaram que essa luta seria vencida, não por mim, mas por toda uma equipe que trabalhou, acreditou e lutou para que esse sonho se realizasse. Obrigado meus pais. A minha história começa com vocês e meu coração estará sempre com vocês.

Dois anos se passaram, nesse tempo eu não fui um cientista, matemático ou astronauta explorando mundos distantes, mas pude aprender sobre a parcela de responsabilidade que todos carregamos enquanto vivemos. Isso quer dizer que me aperfeiçoei como engenheiro, estudante e ser humano, isso quer dizer que me aperfeiçoei como filho, isso quer dizer que me tornei pai. Obrigado amigos, pelos valores, técnicas piadas e problemas que me trouxeram e que tornaram possível essa trajetória.

Quantas e quantas vezes, após um dia difícil de trabalho, eu chegava em casa, abatido, deprimido pelas lutas do dia a dia. Bastava, no entanto, ouvir sua voz, olhar para você meu amor, e de repente eu sentia que tudo tinha valido a pena. Karla minha queria esposa, obrigado pela força, suporte e acima de tudo, AMOR. A dor da distância tem sido uma constante em nossas vidas, mas isso está acabando minha querida. Sem você, nada do que foi feito nesse trabalho teria sido feito. Meu coração é seu hoje e será sempre assim. Obrigado meu amor.

Gostaria também de agradecer a uma pessoa inicial que acompanhou esse estudo desde seu passo inicial até a sua conclusão, Marlice Fernandes Oliveira. Obrigado Marlice pela motivação, acompanhamento, sugestões e apoio ao longo dessa caminhada.

Obrigado a todos os funcionários do Centro de Referência Nacional em Dermatologia Sanitária e Hanseníase da Universidade Federal de Uberlândia pela ajuda e suporte oferecidos. Agradeço ainda a todos os participantes dessa pesquisa que se disponibilizaram prontamente para que pudesse criar o banco de dados dessa pesquisa.

Obrigado aos órgãos de fomento que financiam não somente a minha pesquisa, mas milhares de pessoas como eu que estão fazendo o que faço pelo Brasil. Obrigado CAPES, FAPEMIG e CNPq.

RESUMO

Muitos estudos na área de engenharia biomédica e de ciências da saúde têm buscado a área de aprendizado de máquina para desenvolver métodos que sejam capazes de identificar padrões em diferentes conjuntos de dados. Apesar de extinta em muitos países do primeiro mundo, a hanseníase ainda é uma doença que atinge uma grande parte da população de países como Índia e Brasil. Nesse contexto, essa pesquisa visa a criação de um método que possibilite futuramente entender como a hanseníase afeta os músculos da face. Utilizando a eletromiografia de superfície, um sistema foi adaptado para que se pudesse captar os sinais do maior número possível dos músculos da face desses indivíduos. Buscou-se primeiro na literatura a forma como pesquisadores ao redor do mundo estão trabalhando com doenças que afetam o sistema nervosa periférico e como a eletromiografia tem atuado para contribuir no entendimento dessas doenças. A partir dessas informações, um protocolo foi proposto para se coletar sinais eletromiográficos (sEMG) da face de forma que estes sinais apresentassem uma alta relação sinal/ruído. Depois de coletar os sinais, os pesquisadores buscaram um método que possibilitasse a visualização dessa informação de forma que fosse possível garantir que o método utilizado apresentava resultados satisfatórios. Após identificar que o método foi eficaz, os pesquisadores buscaram entender quais as informações podem ser extraídas do sinal de eletromiografia que representem os dados coletados. Como não se encontrou na literatura estudos que demonstrem quais informações podem contribuir para melhor entendimento dessa patologia, foram extraídos do sinal parâmetros de amplitude, frequência e entropia, e um algoritmo de seleção de características foi utilizado para que se buscasse as características que melhor distinguem um indivíduo saudável do patológico. Em seguida buscou-se identificar o classificador que melhor discriminou indivíduos saudáveis daqueles com hanseníase. Foi identificado que o protocolo proposto neste estudo e a adaptação feita nos eletrodos descartáveis presentes no mercado se mostraram eficientes e que podem ser utilizadas em diferentes estudos quando se deseja coletar dados da eletromiografia da face. O algoritmo de seleção de características também mostrou que nem todas as características extraídas do sinal são significantes para a classificação dos dados, sendo algumas mais relevantes do que outras. O classificador Support Vector Machine (SVM) – Máquina de Vetores de Suporte - se mostrou eficiente quando utilizada a função Kernel adequada para o músculo em que se deseja extrair as informações. Cada músculo estudado neste artigo apresentou resultados diferentes

quando o classificador utilizou funções Kernel linear, radial e polinomial. Embora tenha focado em hanseníase, o método utilizado aqui pode ser aplicado para estudar eletromiografia da face em inúmeras outras patologias.

Palavras-chave: Aprendizado de máquina; hanseníase; eletromiografia; extração de características; seleção de características; máquina de vetores de estado.

ABSTRACT

A number of studies in the areas of Biomedical Engineering and Health Sciences have employed machine learning tools to develop methods capable of identifying patterns in different sets of data. Despite its extinction in many countries of the developed world, Hansen's disease is still a disease that affects a huge part of the population in countries such as India and Brazil. In this context, this research proposes to develop a method that makes it possible to understand in the future how Hansen's disease affects facial muscles. By using surface electromyography, a system was adapted so as to capture the signals from the largest possible number of facial muscles. We have first looked upon the literature to learn about the way researchers around the globe have been working with diseases that affect the peripheral neural system and how electromyography has acted to contribute to the understanding of these diseases. From these data, a protocol was proposed to collect facial surface electromyographic (sEMG) signals so that these signals presented a high signal to noise ratio. After collecting the signals, we looked for a method that would enable the visualization of this information in a way to make it possible to guarantee that the method used presented satisfactory results. After identifying the method's efficiency, we tried to understand which information could be extracted from the electromyographic signal representing the collected data. Once studies demonstrating which information could contribute to a better understanding of this pathology were not to be found in literature, parameters of amplitude, frequency and entropy were extracted from the signal and a feature selection was made in order to look for the features that better distinguish a healthy individual from a pathological one. After, we tried to identify the classifier that best discriminates distinct individuals from different groups, and also the set of parameters of this classifier that would bring the best outcome. It was identified that the protocol proposed in this study and the adaptation with disposable electrodes available in market proved their effectiveness and capability of being used in different studies whose intention is to collect data from facial electromyography. The feature selection algorithm also showed that not all of the features extracted from the signal are significant for data classification, with some more relevant than others. The classifier Support Vector Machine (SVM) proved itself efficient when the adequate Kernel function was used with the muscle from which information was to be extracted. Each investigated muscle presented different results when the classifier used linear, radial and polynomial kernel functions. Even though we have focused on Hansen's disease, the method applied here can be used to study facial electromyography in other pathologies.

Keywords: Machine learning; Hansen's disease; electromyography; feature extraction; feature selection; support vector machine.

LISTA DE FIGURAS

Figura 1: Diagrama de blocos do hardware do sistema de aquisição de dados	24
Figura 2: Diagrama de blocos do trabalho feito	26
Figura 3: Imagem do chip Intan	27
Figura 4: Imagem do chip Intan conectado ao adaptador Omnetics	27
Figura 5: Eletrodo adaptado ao lado do eletrodo comum	28
Figura 6: Participante da pesquisa com os eletrodos antes da adaptação do lado esquerdo e participante após a adaptação dos eletrodos do lado direito	28
Figura 7: Comparação do eletrodo usual com o adaptado	29
Figura 8: Imagem da placa de interface USB ligada a placa amplificadora Intan	29
Figura 9: Movimento da Atividade 1: elevar as sobrancelhas	32
Figura 10: Movimento da Atividade 2: fechar os olhos com força	33
Figura 11: Movimento da Atividade 3: sorrir de forma que apareça os dentes	33
Figura 12: Movimento da Atividade 4: pressionar os dentes de cima contra os dentes de baixo	33
Figura 13: Movimento da Atividade 5: protrusão labial	34
Figura 14: Diagrama de blocos do processamento dos dados	34
Figura 15: Sinal filtrado (A), frequência instantânea (B) e amplitude instantânea (C)	36
Figura 16: Janelamento do sinal	38
Figura 17: Diagrama de blocos do algoritmo de seleção de características	42
Figura 18: Forma que o classificador apresenta os resultados	45
Figure 19: Projeção das atividades realizadas pelos participantes da pesquisa utilizando o PCA	47

Figura 20: Gráfico de pontos de uma das características escolhidas pelo algoritmo de seleção de características	48
Figura 21: Gráfico de pontos de uma das características rejeitada pelo algoritmo de seleção de características	49
Figura 22: Desempenho de todos os músculos utilizando SVM com Kernel linear	55
Figura 23: Desempenho de todos os músculos utilizando SVM com Kernel radial	55
Figura 24: Desempenho de todos os músculos utilizando SVM com Kernel polinomial.	55

SUMÁRIO

1.	INTRODUÇÃO E JUSTIFICATIVA.....	17
1.1	Objetivo Principal.....	19
1.2	Objetivos Específicos.....	19
1.3	Publicações e submissões.....	20
2.	FUNDAMENTAÇÃO TEÓRICA.....	21
2.1	Hanseníase.....	21
2.2	Eletromiografia de superfície.....	22
2.3	Aquisição.....	23
2.4	Pré-processamento do sinal.....	24
2.5	Conversão Analógico/Digital (A/D)	25
3.	MATERIAIS E MÉTODOS.....	26
3.1	Hardware.....	26
3.1.1	Chip Intan RHD2216.....	26
3.1.2	Cabeamento para aquisição dos sinais.....	27
3.1.3	Placa de interface USB.....	29
3.2	Coleta de dados.....	30
3.2.1	Critérios de inclusão e exclusão.....	30
3.3	Protocolo experimental.....	31
3.4	Processamento dos dados.....	34
3.4.1	Filtragem.....	35
3.4.2	Geração do sinal filtrado, amplitude e frequência instantâneas.....	36
3.4.2.1	Amplitude instantânea.....	36

3.4.2.2	Frequência instantânea.....	37
3.4.3	Janelamento.....	37
3.4.4	Extração das características.....	38
3.4.4.1	Amplitude	39
3.4.4.1.1	Valor quadrático médio (RMS)	39
3.4.4.1.2	Valor médio absoluto (MAV)	39
3.4.4.1.3	Valor médio absolute da primeira e da segunda derivada (MAVFD e MAVSD)	39
3.4.4.1.4	Pico.....	40
3.4.4.2	Frequência.....	40
3.4.4.2.1	Cruzamento por zero	40
3.4.4.2.2	Banda de passagem	40
3.4.4.3	Entropia	41
3.4.4.3.1	Entropia aproximada (ApEn)	41
3.4.4.3.2	Entropia fuzzy (FuzEn)	41
3.4.5	Normalização dos dados	42
3.4.6	Seleção de características	42
3.4.7	Support Vector Machine	43
3.5	Análise Estatística	44
3.5.1	Matriz 2x2	44
3.5.2	Sensibilidade	44
4.5.3	Especificidade	45
4.5.4	Acurácia	46

4.5.5 Precisão	46
4. RESULTADOS	47
5. CONSIDERAÇÕES FINAIS	56
5.1 Discussão	56
5.2 Conclusão	59
5.3 Trabalhos futuros	60
REFERÊNCIAS	62

Prefácio

Esta dissertação foi dividida em 5 capítulos.

O primeiro capítulo trata da introdução, considerações iniciais, motivação e justificativa para a execução desse trabalho.

O Capítulo 2 trata da história da hanseníase, desde os seus registros mais antigos, como tem sido tratada e lidada ao passar dos anos. Também é dito neste capítulo como a hanseníase tem progredido e sido praticamente erradicada em alguns países do mundo o que é provavelmente o motivo por poucos trabalhos serem publicados lidando com essa doença. Este capítulo ainda trata da principal ferramenta utilizada para a realização deste trabalho que é a eletromiografia. É explicado o motivo de se usar a eletromiografia neste estudo e como ela tem sido usada e ajudado a entender melhor diferentes patologias ao redor do mundo. É explicado também como funciona o sinal captado e todo o caminho que o sinal percorre até ser finalmente captado pelo equipamento que é então tratado no capítulo seguinte.

O Capítulo 3 detalha todo o material utilizado para realizar este estudo e como esse material foi aplicado para se alcançar os objetivos traçados. Como é necessário detalhar e explicar o motivo de se utilizar cada equipamento e cada método, o Capítulo 3 é o mais longo desse trabalho.

O Capítulo 4 mostra os resultados que foram obtidos quando utilizado todos os métodos descritos no capítulo anterior. Nele estão contidos os resultados que resumem a coleta de dados, os testes feitos para a extração e seleção de características e os resultados obtidos com o classificador.

O Capítulo 5 trata das considerações finais, em que são discutidos os resultados obtidos, e são expostas a conclusão do trabalho e propostas para futuros trabalhos.

Capítulo 1

1. INTRODUÇÃO E JUSTIFICATIVA

A hanseníase é uma doença infecciosa crônica causada pelo *Mycobacterium leprae* (*M. leprae*) que tem predileção por nervos periféricos e pele (Rees et al., 1985). Apresenta uma classificação clínica espectral de Ridley & Jopling (Ridley et al., 1966), que separa as formas clínicas de hanseníase em dois pólos estáveis bem definidos, tuberculóide e virchowiano, e um grupo instável, denominado dimorfo, subdividido em três formas clínicas: dimorfa-tuberculóide, dimorfa-dimorfa e dimorfa-virchowiana (Ridley et al., 1966). Além de causar alterações dermatológicas, o *M. leprae* nos nervos periféricos provoca desmielinização e posteriormente dano axonal (Van Brakel et al., 2008). A bainha de mielina é responsável por acelerar a condução nervosa e quando destruída, provoca perdas na sensibilidade e na motricidade dos músculos inervados por esses neurônios, devido à lentificação da transmissão de informação (Van Brakel et al., 2008).

Essas alterações sensitivas e motoras afetam principalmente as partes periféricas do corpo, tais como pés, mãos e face. A conclusão que muitos estudos trazem é que a variabilidade desses padrões podem ser a fonte de informação para discriminação de padrões em diferentes populações. Os principais nervos acometidos na hanseníase são: facial (VII par craniano), trigêmeo (V par craniano), ulnar, mediano, radial, fibular comum e nervo tibial (Van Brakel et al., 2008). Como na hanseníase observa-se comprometimento dos pares cranianos (V, VII, X) (Dhar et al., 1993), surgiu a necessidade de avaliar os músculos da face.

A eletromiografia (EMG) tem se mostrado uma ferramenta adequada para a avaliação da integridade de nervos e músculos faciais (Sittel et al., 2001). Este é um método não invasivo (James et al., 2012) e seu sinal pode ser analisado tanto no domínio do tempo quanto no domínio da frequência. O sinal eletromiográfico é oriundo da atividade elétrica das membranas excitáveis das células musculares. O sinal é representado por meio de uma tensão elétrica viajando ao longo do tempo e é o resultado da somatória de todos os sinais presentes no músculo podendo ser afetado por diferentes fatores, tais como, anatomia, fisiologia, propriedades em si do músculo, do equipamento,

dos sensores utilizados para a captação do sinal (Basmajian et al., 1962) e do ambiente em que é feita a coleta dos dados.

Existe atualmente uma iniciativa da União Européia chamada SENIAM (Surface Electromyography for the Non-Invasive Assessment of Muscles) que visa solucionar itens chave que dificultam a troca de dados e experiência clínica entre pesquisadores da área de Engenharia Biomédica e Ciências da Saúde. Esta iniciativa fornece dados sobre posicionamento de eletrodos, tipo de eletrodos que devem ser usados em eletromiografia para diferentes partes do corpo, porém até a data da escrita dessa dissertação, o projeto SENIAM não fornece um padrão para a coleta de dados de eletromiografia da face. A literatura investigada sugere a avaliação eletromiográfica da face como suporte diagnóstico para diferentes doenças fornecendo dados objetivos na avaliação da integridade motora dos músculos da cabeça e do pescoço, porém a escolha dos músculos varia muito entre os autores, variando também os procedimentos de avaliação (Bernardes et al., 2010; Hughes et al., 2015; Furlan et al., 2015).

Doenças desmielinizantes como a hanseníase, esclerose múltipla, distrofias musculares, amiotrofias ou até mesmo a Síndrome de Guillain-Barré (Ayuso et al., 2008), podem ter como seqüela alterações que envolvem a musculatura cervical e facial. Desta forma, considera-se relevante uma investigação detalhada da atividade eletromiográfica desses músculos que favoreça uma padronização e que permita a comparação entre indivíduos sadios e portadores de doenças com alterações motoras e sensitivas. Apesar de existirem estudos que propõem protocolos para uma avaliação eletromiográfica da face, nota-se que os mesmos, geralmente estão direcionados a um grupo específico de músculos que relacionam a uma determinada função (Pernambuco et al., 2013). Esse estudo busca um método eficiente que seja capaz de avaliar o máximo de músculos da face possíveis em pacientes com hanseníase e avaliar qual o melhor método disponível na área de Aprendizado de Máquina (do inglês, *Machine Learning*) para identificar se há ou não alteração na musculatura da face em pacientes com hanseníase.

Muitos métodos têm surgido para agrupamento de dados (Xu et al., 2010). Semelhantemente, muitos artigos têm sido publicados mostrando técnicas de Aprendizado de Máquina para diferentes tipos de classificadores (Foster et al., 2014), porém estes métodos são específicos para diferentes casos e nenhum deles trata sobre a hanseníase. Com este trabalho, busca-se avaliar diferentes métodos para se chegar

naquele que apresenta os melhores resultados em avaliar dados de eletromiografia de pacientes com hanseníase.

1.1 Objetivo Principal

O principal objetivo desta pesquisa foi avaliar o desempenho do classificador Máquina de Vetores de Suporte na discriminação de diferentes características extraídas de músculos faciais de indivíduos saudáveis e com hanseníase.

1.2 Objetivos específicos

Com a finalidade de se cumprir o objetivo principal, alguns objetivos específicos foram determinados:

- Criar um protocolo que possibilite coletar dados de eletromiografia em diferentes músculos da face em indivíduos com hanseníase e em indivíduos saudáveis;
- Adaptar eletrodos descartáveis convencionais para serem usados para eletromiografia da face;
- Verificar se é possível discriminar todas as atividades dentro do grupo de pacientes de hanseníase e saudáveis;
- Identificar quais características podem ser extraídas do sinal de eletromiografia que são mais relevantes para discriminar o grupo patológico do grupo saudável;
- Avaliar quais os músculos da face podem ser utilizados para a discriminação entre os grupos;
- Avaliar o efeito de diferentes parâmetros do classificador sobre os resultados obtidos.

1.3 Publicações e submissões

PERES, L. B. ; OLIVEIRA, M. F. ; QUEIROZ, C. M. M. ; GOULART, I. M. B. ; ANDRADE, A. O. “Proposta de um protocolo experimental para detecção de atividade eletromiográfica de músculos faciais em indivíduos com hanseníase”. In: VIII Simpósio em Engenharia Biomédica Uberlândia, 2015, Uberlândia. Anais do VIII Simpósio em Engenharia Biomédica. Bauru: Canal 6, 2015. v. 1. p. 80-84.

OLIVEIRA, M. F.; PERES, L. B.; GOULART, I. M. B.; ANDRADE, O. A. “Avaliação Fonoaudiológica Clínica em Portadores de Hanseníase. ” In: 8º Simpósio Brasileiro de Hansenologia. São Paulo: 2015

SILVA G. M.; PERES, L. B.; LUIZ, L. M D.; OLIVEIRA I. M., ANDRADE A. O. “Estudo do índice de correlação cruzada entre a atividade eletromiográfica do músculo frontal e o eletroencefalograma”. In: XXV Congresso Brasileiro de Engenharia Biomédica – CBEB 2016.

OLIVEIRA, M. F.; PERES, L. B.; QUEIROZ C. M.; ANDRADE A. O.; GOULART, I. M. B. “Avaliação eletromiográfica da musculatura suprahióidea durante a deglutição em pacientes com hanseníase virchowiana”. In: XXV Congresso Brasileiro de Engenharia Biomédica – CBEB 2016.

Capítulo 2

2. FUNDAMENTAÇÃO TEÓRICA

2.1. HANSENÍASE

A hanseníase é uma doença infecciosa crônica causada pelo *Mycobacterium leprae* que tem predileção por nervos periféricos e pele (Res et al., 1992). O registro mais antigo da hanseníase se encontra na Bíblia sagrada, no livro de Números, que foi escrito por volta de 3500 anos atrás. No livro de Números, o indivíduo infectado com a essa doença era colocado em um lugar afastado das pessoas que não tinham a doença e era considerado impuro. Enquanto que a sociedade morava nas cidades, protegidas por seus muros, os leprosos eram obrigados a viver nos arredores da cidade, fora dos muros. Até mesmo o rei quando era infectado com a doença era obrigado a sair do palácio e viver afastado com as outras pessoas que tinham a doença. Neste contexto, todas as pessoas que tocassem em um leproso se tornariam impuras e deveriam se afastar da cidade por um período de dias até que se purificassem (Neyra et al., 1994).

A hanseníase apresenta uma classificação clínica espectral de Ridley & Jopling (Ridley et al., 1966). Além de causar alterações dermatológicas, o *M. leprae* nos nervos periféricos provoca desmielinização e posteriormente dano axonal (Van Brakel et al., 2008). A bainha de mielina é responsável por acelerar a condução nervosa e quando destruída, provoca perdas na sensibilidade e na motricidade dos músculos inervados por esses neurônios, devido à lentificação da transmissão de informação. Essas alterações sensitivas e motoras afetam principalmente as partes periféricas do corpo, tais como pés, mãos e face. Os principais nervos acometidos na hanseníase são: facial (VII par craniano), trigêmio (V par craniano), ulnar, mediano, radial, fibular comum e nervo tibial.

A investigação dos músculos da face por meio da eletromiografia de superfície pode contribuir para um maior esclarecimento a respeito das características da hanseníase.

A hanseníase não pode ser transmitida de pai para filho, porém a convivência entre uma pessoa com hanseníase e uma pessoa saudável, pode levar o indivíduo saudável a contrair a doença e sua evolução depende do sistema imunológico da pessoa infectada. A prevalência da hanseníase tem diminuído ao redor do mundo desde a introdução de

medicamentos eficazes no seu tratamento. Após ingerida a primeira dose, o indivíduo deixa de transmitir a doença. Essa forma de medicação foi primeiramente introduzida em 1982 e o número de casos de hanseníase no mundo caiu de 5,4 milhões em 1985 para 0,88 milhões em 1997 (Ho et al., 1999). Apesar de alguns países ao redor do mundo declararem que o índice de prevalência da hanseníase tem diminuído, alguns pesquisadores têm publicado estudos demonstrando o contrário. Os países do mundo que apresentam mais caso de hanseníase todo ano são a Índia e em segundo lugar o Brasil. Melhores condições de saneamento básico também tem ajudado a diminuir o número de novos casos de hanseníase em muitos países ao redor do mundo.

Estudos têm demonstrado a ação do *M. leprae* em partes periféricas do corpo como mãos e pés, porém pouco tem sido falado sobre como a hanseníase afeta os músculos da face. Muitos artigos são publicados demonstrando como a eletromiografia pode ajudar na compreensão de diferentes doenças, porém, um método eficiente para se captar sinais de eletromiografia da face com a hanseníase não foi encontrado na literatura. Surgiu então a necessidade de se abordar esse tema, fornecendo assim métodos e ferramentas que possibilitem a pesquisadores futuramente a entender melhor como o *M. leprae* pode influenciar os músculos da face.

2.2. Eletromiografia de superfície

O sinal eletromiográfico é oriundo da atividade elétrica das membranas excitáveis das células musculares. O sinal é representado por meio de uma tensão elétrica viajando ao longo do tempo e é o resultado da somatória de todos os sinais presentes no músculo podendo ser afetado por diferentes fatores, tais como, anatomia (pessoas com excesso de tecido adiposo aumentam a impedância da pele, diminuindo assim a intensidade do sinal coletado), fisiologia, propriedades em si do músculo analisado (alguns músculos apresentam uma atividade mais intensa quanto expostos a máxima contração do que outros), do equipamento e dos sensores utilizados para a captação do sinal (Basmajian et al., 1962).

Antes de entender o sinal eletromiográfico, é preciso entender sobre a estrutura dos músculos. As fibras musculares são inervadas em grupos, que são chamados de unidades motoras (UM) que quando são ativados, geram um potencial de ação, chamado de potencial de ação da unidade motora (PAUM). Estes potenciais de ação aparecem

enquanto o músculo está contraído, diminuindo sua intensidade conforme aquele músculo vai relaxando. Esta repetição de potenciais de ação recebe o nome de trem de potencial de ação (TPAUM). O sinal eletromiográfico é composto por essas TPAUMs. Sendo assim, quanto mais força o indivíduo faz com aquele músculo, quanto mais o músculo é contraído, maior será o TPAUM e de mais intensidade será o sinal eletromiográfico (De Luca et al., 2006).

O sinal eletromiográfico pode ser analisado tanto no domínio do tempo como no domínio da frequência. No domínio do tempo podem se extrair características que normalmente estão associadas a intensidade com que o músculo foi contraído. As características mais utilizadas na literatura são RMS (valor médio quadrático) e MAV (valor médio absoluto), podendo desta última se extrair outras características com a primeira e a segunda derivada. No domínio da frequência podemos analisar o espectro de potência do sinal, o que permite quantificar características como frequência mediana, frequência média e frequência modal (Tan et al., 2012).

2.3 Aquisição

A aquisição da eletromiografia de superfície (sEMG) pode ser feita de forma não invasiva utilizando eletrodos que são posicionados na superfície da pele do indivíduo. Neste estudo foram utilizados eletrodos adesivos que foram ajustados para se adaptarem a realidade dos músculos da face que apresentam área reduzida. Além dos eletrodos posicionados sobre os músculos estudados, é posicionado um eletrodo sobre uma protuberância óssea como referência.

Quando uma pessoa ativa um músculo, o estímulo é gerado no cérebro da pessoa que então viaja até chegar no músculo que o indivíduo teve intenção de acionar. Chegando no músculo, o eletrodo posicionado sobre aquele local capta os TPAUMs que são representados para o equipamento como variação de tensão no tempo. Essa tensão é da ordem de microvolts (μV), então quando captado pelo sensor, este sinal precisa ser pré-amplificado. O sinal é coletado utilizando sensores bipolares, isto quer dizer que um par de eletrodos é posicionado sobre os músculos e o sinal resultante é a subtração destes dois sinais.

2.4 Pré-processamento do sinal

Como dito anteriormente, o sinal EMG é coletado em microvots por tanto precisa ser amplificado. O sinal resultante da subtração dos dois eletrodos posicionados sobre o músculo é amplificado em uma escala de milivolts (mV) logo após a captação do sinal.

Após amplificado, o sinal é então filtrado. O processo de filtragem serve para eliminar frequências indesejadas no sinal. Para esta coleta foi utilizado um filtro passa alta de 20 Hz e um filtro passa baixa de 500 Hz. Isto significa que qualquer sinal de frequência menor que 20 Hz e maior que 500 Hz será eliminado do sinal. Esta faixa de frequência foi escolhida levando em conta a predominância da frequência do sinal eletromiográfico, que se encontra dentro dessa faixa (Merletti et al., 2009). O filtro passa alta é responsável por eliminar frequências de offset que inserem tendências não lineares no sinal e um sinal de offset que fica na faixa dos 0 a 10 Hz. O filtro passa baixa é responsável por eliminar frequências altas que geram ruídos indesejáveis no sinal e harmônicos. Também é utilizado um filtro tipo Notch de 60 Hz como sugerido por (de Luca et al., 2010). A arquitetura geral de aquisição de dados é mostrada na Figura 1.

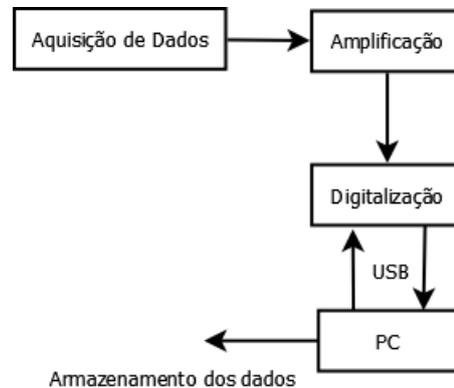


Figura 1: Diagrama de blocos do hardware do sistema de aquisição de dados.

O sinal eletromiográfico foi coletado utilizando um chip amplificador da Intan de 16 canais RHD2216 (Intan Technologies LLC) com taxa de amostragem de 5000 Hz. Segundo o Teorema de Nyquist, a frequência de amostragem deve ser no mínimo o dobro da maior frequência do sinal amostrado. Como citado anteriormente, a frequência de corte do sinal foi ajustada em 500 Hz, portanto a menor frequência de amostragem desse sinal deveria ser 1000 Hz. A escolha por 5000 Hz veio pelo fato de estar dentro dos parâmetros do Teorema de Nyquist e possibilitar que todos os aspectos da atividade que se deseja detectar pudessem ser vistos de forma fidedigna. O RHD2216 possui um arranjo de

amplificadores de baixo ruído interno com largura de banda programável e pode ser utilizado para coleta de outros biopotenciais além de sinais eletromiográficos.

2.5 Conversão analógica/digital (A/D)

Uma variável analógica é aquela que pode assumir infinitos valores dentro de uma faixa, diferentemente das variáveis discretas que só podem assumir dois valores, geralmente 0 e 1. As TPAUMs, como dito anteriormente, são convertidas em tensão elétrica e conforme a contração do músculo é mais intensa, o mesmo acontece com o sinal EMG. Este sinal EMG que é analógico, precisa ser convertido para um sinal digital que o microcontrolador possa compreender. O teorema de Nyquist diz que todo sinal analógico convertido para digital deve ser amostrado com uma taxa no mínimo duas vezes maior que a maior frequência do sinal coletado, neste caso 500 Hz, para se evitar o fenômeno chamado de *espalhamento*. Na prática este teorema pode não ser o mais adequado, visto que se amostrássemos o sinal EMG com uma taxa de 1000 Hz, o sinal poderia perder informações valiosas a esse estudo. Para se contornar esse problema, o sinal coletado foi amostrado com uma taxa de 5000 Hz.

A conversão A/D é então feita transformando sinais de tensão amostradas em níveis representados em escalas discretas de 0 ou 1. Dessa forma, a tensão do sinal coletado é dividida em níveis discretos dados por $2^n - 1$, onde n é o número de bits do conversor A/D. Quanto maior for o n maior será a resolução do sinal.

Capítulo 3

3. MATERIAIS E MÉTODOS

O estudo experimental realizado nessa pesquisa teve aprovação do Comitê de Ética. O nome do projeto é: Avaliação fonoaudiológica clínica e eletromiográfica da face na hanseníase (CAAE: 41933614.3.0000.5152).

Esta pesquisa foi dividida em 5 fases como mostrado no diagrama da Figura 1. A sequência de passos executados para a realização desse trabalho é ilustrada na Figura 2:



Figura 2: Diagrama de blocos da divisão do trabalho.

3.1 Hardware

Os equipamentos utilizados nesta pesquisa foram adaptados para o uso na face.

3.1.1 Chip Intan RHD2216

Para a amplificação do sinal foi utilizado o chip da empresa Intan Technologies LLC, RHD2216. Este dispositivo possui um arranjo de amplificadores de baixo ruído interno e pode ser utilizado para a aquisição de diferentes biopotenciais como ECG, EMG e EEG. O circuito é composto por filtros analógicos programáveis, amplificadores e um conversor analógico/digital de 16 bits. O chip pode ser visto na Figura 3. O chip se conecta ao sistema de aquisição por um soquete e a interface através de um cabo de interface SPI.

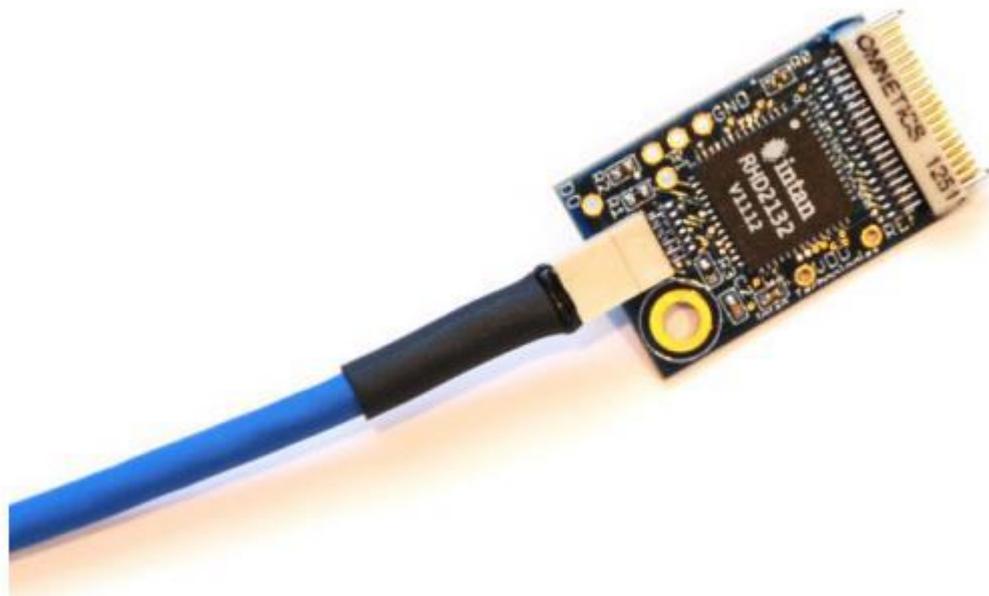


Figura 3: Imagem do chip Intan.

Para a conexão com os cabos que fazem a coleta de dados, é utilizado um soquete adaptador Omnetics e um soquete de 16 pinos. Na Figura 4 é possível ver o chip Intan conectado ao adaptador Omnetics.



Figura 4: Imagem do chip Intan conectado ao adaptador Omnetics.

3.1.2 Cabeamento para aquisição dos sinais

Foi desenvolvido também um cabeamento e uma adaptação nos eletrodos para que pudesse ser utilizado para captar sinais de eletromiografia da face. Eletrodos descartáveis utilizados hoje no mercado, mesmo os utilizados em crianças, possuem uma área superior maior do que se necessita para coletar EMG da face. Para solucionar este problema, foi criado um cortador de eletrodos, para que se pudesse extrair somente o núcleo do eletrodo diminuindo assim a área total do eletrodo. A adaptação é mostrada na Figura 5:



Figura 5: Eletrodo adaptado ao lado do eletrodo comum.

Foi necessário esse ajuste na dimensão dos eletrodos pois os músculos da face possuem uma área reduzida e os eletrodos no seu tamanho padrão, se posicionam sobre muitos músculos ao mesmo tempo. A Figura 6 mostra os eletrodos de tamanho normal e a adaptação feita posicionados sobre o rosto de participantes da pesquisa.



Figura 6: Participante da pesquisa com os eletrodos antes da adaptação do lado esquerdo e participante após a adaptação dos eletrodos do lado direito.

Quando se utilizou os eletrodos adaptados, surgiu o desafio de como posicioná-los sobre o músculo desejado sem que eles caíssem do músculo, pois toda a área do eletrodo responsável pela aderência sobre o músculo foi removida. Para diminuir o efeito da gravidade sobre o eletrodo foi desenvolvido um cabeamento mais fino e mais leve e o participante da pesquisa foi colocado na posição decúbito dorsal. O cabeamento desenvolvido pode ser visto na Figura 7:



Figura 7: Comparação do eletrodo usual com o adaptado.

3.1.3 Placa de interface USB

A placa de interface USB utilizada foi a *RHD2000 Interface Evaluation System*. Esta placa permite que sejam conectadas quatro placas amplificadoras podendo estas serem de 16, 32, 64 ou 128 canais monopolares ou bipolares. A Figura 8 mostra a placa de interface ligada a uma placa amplificadora.

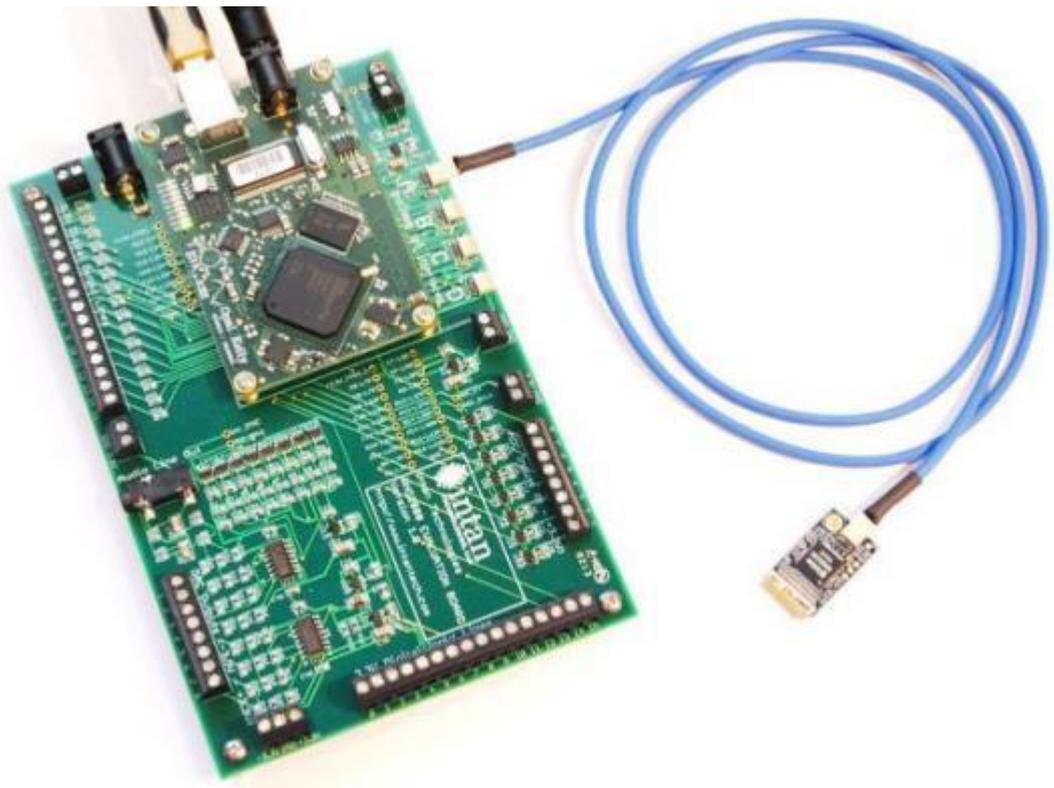


Figura 8: Imagem da placa de interface USB ligada a placa amplificadora Intan.

A empresa *Intan Techonologies LLC* também disponibiliza em seu website, uma plataforma *open-source* para *download* escrita em C++ que permite programar filtros, controlar a operação dos amplificadores e fornece visualização em tempo real dos dados que estão sendo coletados. Para a coleta do sinal, foi ajustado uma banda de passagem de 20 a 500 Hz como sugerido por (Boxtel et al., 2001) com um filtro Notch de 60 Hz programado no próprio equipamento antes da coleta dos dados.

3.2 Coleta de dados

A primeira pergunta a ser respondida foi qual eletrodo utilizar, pois os músculos da face apresentam uma área reduzida e os eletrodos encontrados no mercado possuíam um tamanho acima do desejado e traziam um imenso desconforto para o indivíduo que participava da coleta de dados. Para responder a essa pergunta, foi adaptado o sistema para o uso específico para eletromiografia da face, sem que eles perdessem a sua capacidade de captar o sinal (Peres et al., 2015). Com os eletrodos menores, surgiu um novo desafio, pois a área dos eletrodos que adere a pele também foi reduzida e isso levava os eletrodos a não ficarem no local desejado. Este fator levou a pesquisa a se limitar aos músculos que apresentaram sinais com uma alta relação sinal/ruído durante o teste piloto.

Desejou-se inicialmente analisar mais músculos da face, porém devido ao movimento do próprio músculo, o eletrodo não permanecia sobre o músculo desejado. Alguns músculos por serem mais profundos, não apresentaram uma boa relação sinal/ruído quando captados pela superfície da pele como a musculatura infrahióidea. Para resolver esse problema, utilizou-se um cabeamento mais fino para diminuir o efeito da gravidade sobre o eletrodo e o participante da pesquisa foi colocado na posição decúbito dorsal. Alguns músculos tiveram de ser evitados pois o sinal coletado não apresentou uma boa relação sinal/ruído. Para a coleta foram utilizados eletrodos plásticos descartáveis Kendall Meditrace.

Este estudo teve um total de 60 participantes sendo 30 com hanseníase e 30 saudáveis.

3.2.1 Critérios de inclusão e exclusão

Para essa pesquisa foram estabelecidos alguns critérios de exclusão que são aplicáveis ao grupo dos saudáveis (G1) e ao grupo com hanseníase (G2). Em nenhum grupo, o indivíduo poderia estar fazendo uso de botox nem ingerindo qualquer medicação

que tivesse influência no sistema nervoso central ou periférico. Foi pedido aos homens que se barbeassem antes da coleta dos dados. Aqueles que se negaram a fazer a barba foram excluídos. Para a participação desse estudo, os voluntários deveriam estar dentro de uma faixa de 18 a 60 anos de idade, dando-se preferência para indivíduos com menos de 35 anos de idade.

O G1 possui uma idade média de 31,69 anos de idade. Nenhum indivíduo do G1 poderia ter tido hanseníase em algum momento de sua vida ou estar em tratamento de alguma doença que apresentasse influência no sistema nervoso.

O G2 possui uma idade média de 35,67 anos de idade. Os indivíduos que não estivessem fazendo uso da medicação para tratamento da hanseníase foram excluídos e também os indivíduos que apresentaram alterações no seu sistema nervoso central foram excluídos.

3.3 Protocolo experimental

Esse estudo foi conduzido no Centro de Referência Nacional em Dermatologia Sanitária e Hanseníase (CREDESH), Brasil e na Universidade Federal de Uberlândia (UFU), Brasil.

Buscou-se preparar um protocolo que possibilitasse avaliar o máximo de músculos da face possíveis tanto do lado direito quanto do lado esquerdo. Após o teste piloto, ficou evidenciado que os músculos que apresentaram uma melhor relação sinal/ruído e que apresentam relevância para o estudo da hanseníase são: frontal, zigomático, olhos, masseter e boca.

Os músculos estudados são os músculos inervados pelo nervo facial (VII par craniano), responsável pela motricidade da face, sendo eles: frontal direito e esquerdo, zigomático direito e esquerdo, orbicular dos olhos direito e esquerdo e orbicular da boca. Também foi alvo deste estudo o músculo masseter direito e esquerdo que mesmo não sendo inervado pelo nervo facial, contribui com o movimento relacionado a mastigação.

A coleta de dados consiste na avaliação dos músculos em uma série de 3 contrações para cada músculo. Cada série consiste em contrações de 20 segundos cada com intervalo de 5 segundos entre cada contração. O protocolo consiste nas seguintes atividades: primeiramente é avaliado o músculo frontal. O indivíduo deve levantar as

sobrancelhas e mantê-las levantadas por 20 segundos. Após um descanso de 5 segundos, prossegue com mais duas repetições. O próximo músculo analisado é o orbicular dos olhos. Para a análise deste músculo, dois tipos de fechamento ocular são exigidos, ou seja, um com máxima força de fechamento ocular e o outro com fechamento ocular sem esforço. Primeiramente, o indivíduo deve fechar os olhos e mantê-los fechados fazendo força por 20 segundos, para que se possa criar um padrão de normalidade para futuras análises. O mesmo tempo de 5 segundos de descanso é dado entre cada repetição. Terminada as 3 repetições é solicitado ao indivíduo que repita o procedimento anterior, mas desta vez, ele deve fechar os olhos sem fazer força, um fechamento natural. Os olhos devem permanecer fechados durante os 20 segundos e abertos durante o intervalo de 5 segundos entre as seções. O próximo músculo avaliado é o músculo zigomático, tanto direito como esquerdo. É pedido ao indivíduo que tente sorrir de forma que a musculatura do zigomático maior possa ser contraída ao máximo, ou seja, um sorriso aberto, mantendo também por 20 segundos e após descanso são realizadas mais duas repetições similares. O próximo músculo a ser analisado é o masseter. Para a ativação deste músculo, o indivíduo deve pressionar a arcada dentária superior contra a arcada dentária inferior com força, seguindo o mesmo procedimento padrão dos músculos anteriores. O músculo seguinte é o orbicular da boca. Por ser um músculo circular e de área reduzida, é analisado como um todo utilizando um par de eletrodos apenas. Para a ativação deste músculo, é solicitado ao indivíduo que realize uma protrusão labial. Este movimento deve ser mantido por 20 segundos em cada seção com intervalo de 5 segundos entre as seções. As Figuras 9, 10, 11 e 12 demonstram as atividades que os participantes realizaram.

1º Movimento: levantar sobrancelhas e manter por tempo de 20 segundos.

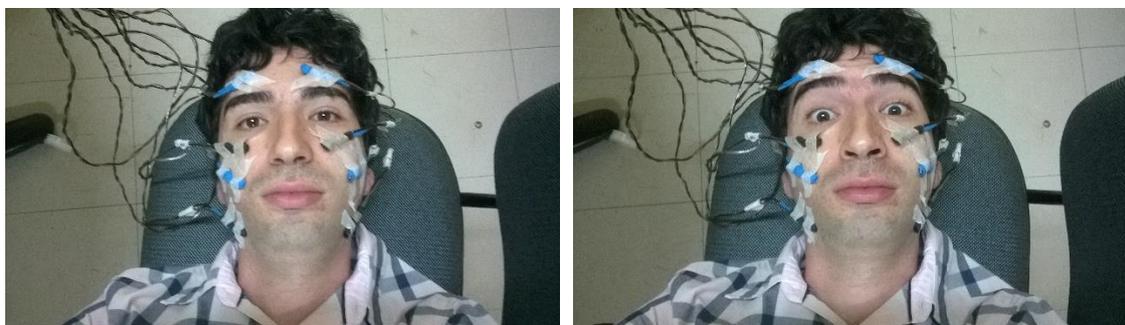


Figura 9: Movimento da Atividade 1: elevar as sobrancelhas.

Este movimento é realizado 3 vezes com um intervalo de 5 segundos entre cada exercício.

2º Movimento: fechar os olhos e mantê-los pressionados com força por 20 segundos.

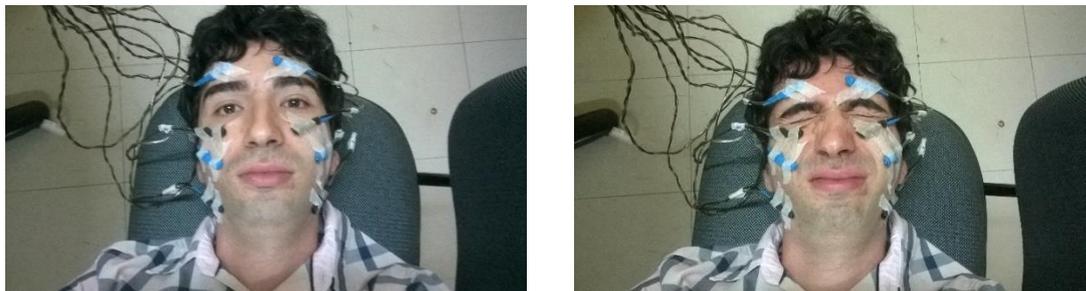


Figura 10: Movimento da Atividade 2: fechar os olhos com força.

Este movimento é realizado 3 vezes com um intervalo de 5 segundos entre cada exercício.

3º Movimento: sorriso aberto sem apertar os dentes por 20 segundos.

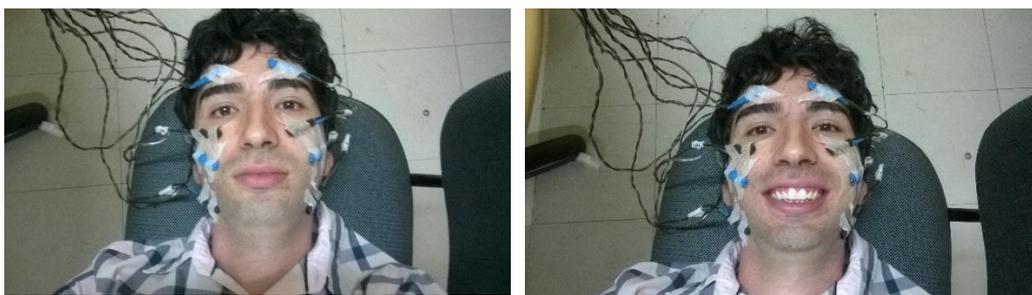


Figura 11: Movimento da Atividade 3: sorrir de forma que apareça os dentes.

Este movimento é realizado 3 vezes com um intervalo de 5 segundos entre cada exercício.

4º Movimento: pressionar os dentes da mandíbula um contra o outro durante 20 segundos.

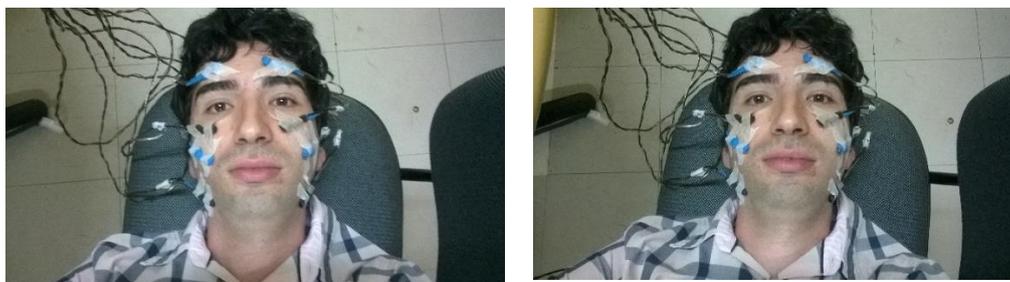


Figura 12: Movimento da Atividade 4: pressionar os dentes de cima contra os dentes de baixo.

Este movimento é realizado 3 vezes com um intervalo de 5 segundos entre cada exercício.

5º Movimento: projeção dos lábios para frente.

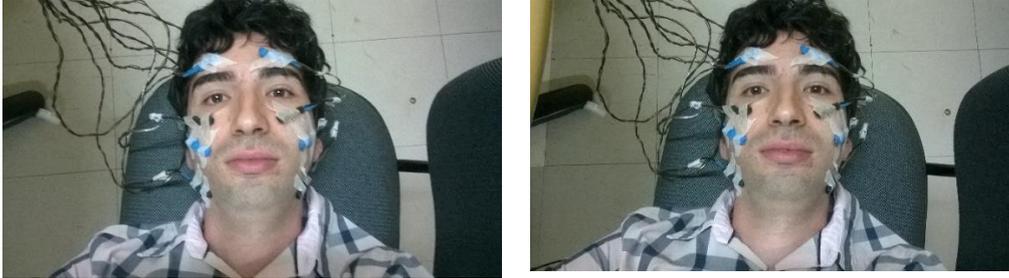


Figura 13: Movimento da Atividade 5: protrusão labial.

Este movimento é realizado 3 vezes com um intervalo de 5 segundos entre cada exercício.

3.4 Processamento dos dados

O processamento dos dados é feito a partir das etapas indicadas na Figura 14.

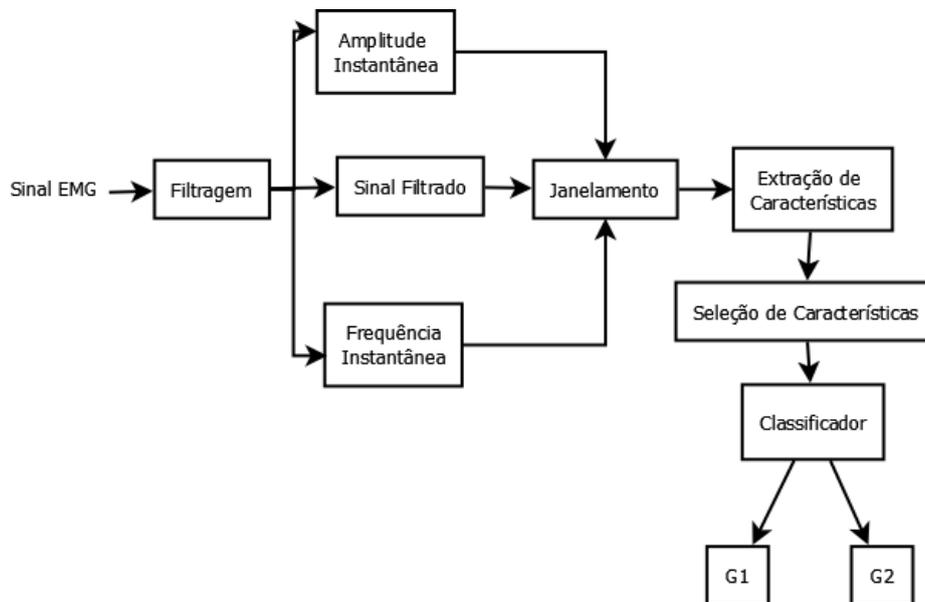


Figura 14: Diagrama do processamento dos dados.

Na primeira parte foi feita coleta de dados de eletromiografia nos pacientes de hanseníase e saudáveis. Posteriormente esses sinais foram filtrados. A partir do sinal de eletromiografia foi gerado um sinal de amplitude e frequência instantânea para cada músculo de cada participante da pesquisa. Como a priori não se conhece quais características são mais relevantes para essa pesquisa, foram extraídas características de

amplitude, frequência e aleatoriedade do sinal filtrado e da amplitude instantânea. Do sinal de frequência instantânea foram extraídas características de amplitude e aleatoriedade.

3.4.1 Filtragem

A filtragem do sinal é uma etapa muito importante no processamento dos dados. Nesta etapa, filtros são ajustados para que se possa concentrar somente nas frequências desejadas. Quando se tem um filtro ajustado propriamente, pode-se eliminar frequências harmônicas e frequências correspondentes a outros biopotenciais que não são o alvo do estudo.

Para se projetar um filtro, deve-se levar em conta a resposta que o sinal apresenta quando filtrado na fase e na amplitude. Em um filtro ideal, a amplitude apresenta um ganho unitário de reposta para a banda de frequência de interesse e ganho 0 para as frequências de rejeição. Também é necessário definir qual será a frequência de corte que no filtro ideal e a frequência onde se inicia a resposta do filtro sobre as frequências de rejeição.

Existem filtros passa alta, passa baixa, passa faixa e rejeita faixa. O filtro passa alta é responsável por amenizar frequências abaixo do valor ajustado. Um filtro passa alta de 20 Hz, irá amenizar todas as frequências abaixo desse valor. O filtro passa baixa, é responsável por amenizar as frequências que estão acima do valor definido, permitindo assim que o sinal não sofra tanto com frequências indesejadas. Um filtro passa faixa une o filtro passa baixa e o passa alta, permitindo que passe somente uma faixa definida de frequências. O passa faixa define dois valores de frequências, e como resposta, o sinal conterà somente as frequências que estiverem entre esses dois valores. Um filtro rejeita faixa, define dois valores e qualquer valor de frequência que estiver entre estes dois valores é rejeitado.

Além dessas definições, filtros podem ser ativos, passivos ou digitais. Um filtro ativo é composto por componentes ativos no circuito como amplificadores operacionais. Um filtro passivo é composto por componentes passivos como indutores, capacitores e resistores. Um filtro digital é um filtro utilizado em sinais digitais (Oppenheim et al., 1989).

Para a coleta do sinal EMG desse estudo, foi ajustado um filtro passa alta de 20 Hz e um filtro passa baixa 500 Hz com um filtro Notch de 60 Hz.

3.4.2 Geração do sinal filtrado, amplitude e frequência instantâneas

A partir do sinal coletado, foi gerado um sinal de frequência instantânea, amplitude instantânea e gerado uma nova série temporal com o sinal filtrado, tal como detalhado em (ANDRADE et al., 2005). Este processo foi feito para cada músculo estudado. Os resultados desse processamento podem ser vistos na Figura 15.

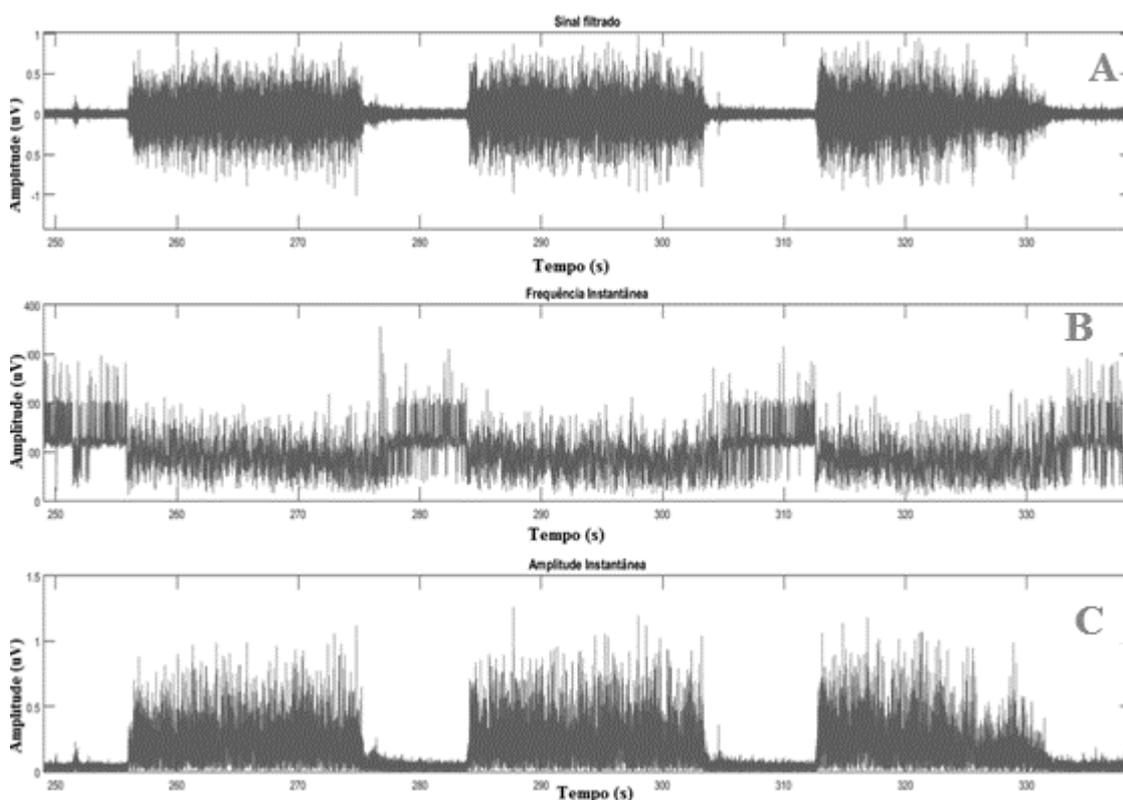


Figura 15: Sinal filtrado (A), frequência instantânea (B) e amplitude instantâneas (C).

Como a priori não se sabe quais características são relevantes para esse estudo buscou-se extrair dos sinais, características da amplitude, frequência e entropia.

3.4.2.1 Amplitude Instantânea

A amplitude instantânea é um conceito muito comum em modulação de sinais ou processamento de sinais em Engenharia Biomédica. Também conhecida como envelope, é descrita como a magnitude do sinal e pode ser estimada por meio da transformada de Hilbert do sinal.

3.4.2.2 Frequência Instantânea

A frequência de uma senóide é uma medida muito bem estabelecida. É o inverso do tempo que o sinal leva para sair de um ponto de repouso, atingir seu valor máximo, cair até seu valor mínimo e então voltar para a situação de repouso. Calcular a frequência de sinais estacionários não é uma tarefa tão complexa, pois basta calcular quantas vezes este sinal se repete por segundo. Quando tratamos de sinais não estacionários como por exemplo um sinal de EMG, esta noção de frequência perde seu sentido. Um sinal não estacionário é um sinal cuja frequência se altera com o tempo. Com a necessidade de se encontrar a frequência destes sinais, surge a ideia de frequência instantânea. A noção de frequência instantânea é geralmente usada na área de comunicações, radar, medidas de tremores sísmicos e em engenharia biomédica. A frequência instantânea é um parâmetro que define a localização do pico do espectro de frequência do sinal conforme ele varia no tempo (Bouashash et al., 1992).

3.4.3 Janelamento

Para agilizar o processo de extração de características um algoritmo de janelamento da atividade foi criado. Para a análise do sinal foi utilizado o *Matlab R2015a* (*MathWorks Inc., USA*). Antes de ser analisado, os dados passaram por um processo de janelamento, em que foi selecionado o trecho do sinal que continha a atividade do músculo estudado. Para a detecção da atividade muscular, um limiar foi estabelecido e quando a amplitude do sinal assumia valores maiores que aquele limiar significava que o sinal representava atividade miolétrica. Quando a amplitude do sinal estivesse abaixo do limiar, implicaria que a atividade muscular cessou. A Figura 16 mostra o sinal com o início e o fim da atividade demarcada. A barra vermelha mostra onde a atividade muscular iniciou e a barra verde mostra onde terminou.

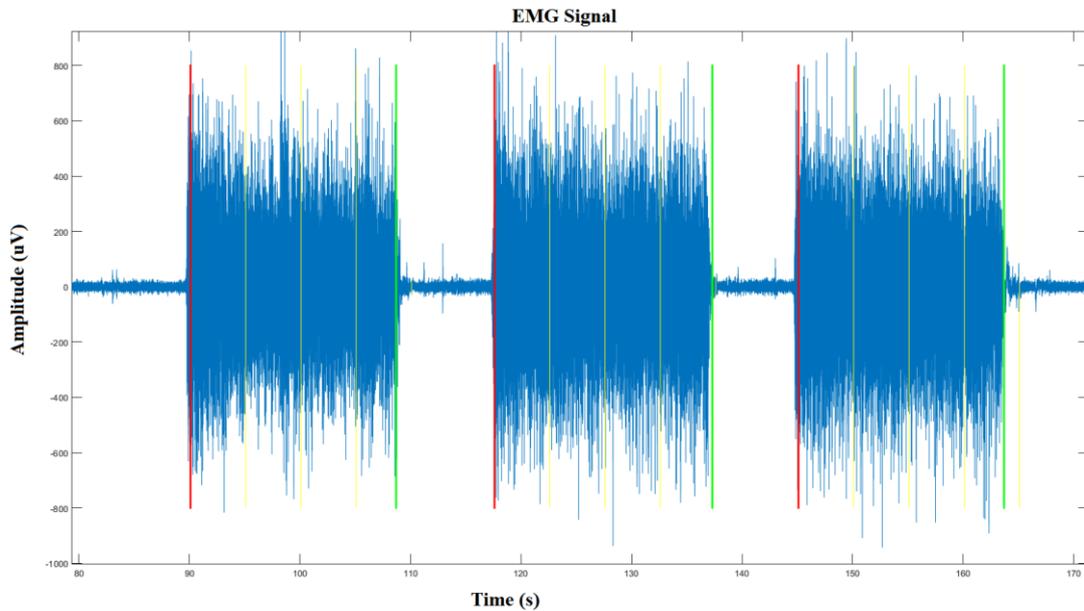


Figura 16: Janelamento do sinal.

Como a contração de cada atividade tem um tempo de aproximadamente 20 segundos, a janela de 20 segundos foi dividida em pequenas janelas de 5 segundos e as características foram extraídas nestes pequenos trechos. A cada trecho de 5 segundos o algoritmo aplicava a extração das características do sinal e salvava essas características em uma tabela multidimensional.

3.4.4 Extração das características

Após o processo de filtragem e janelamento foram extraídas características de amplitude, frequência e entropia aproximada do sinal filtrado e da amplitude instantânea. Do sinal de frequência instantânea foram extraídas somente as características de amplitude e entropia. As características de amplitude extraída foram valor médio quadrático (RMS), valor médio absoluto (MAV), primeira derivada do MAV (MAVFD), segunda derivada do MAV (MAVSD) e tensão de pico (PEAK). As características de frequência extraídas foram a menor frequência da janela (F-), a maior frequência da janela (F+), a frequência mediana (Fmed), a frequência modal (Fmod), a frequência média (Fmean) e o cruzamento por zero (Zc). As características de entropia foram entropia aproximada (ApEn), entropia espectral (SpecEn) e entropia fuzzy (FuzEn). Entropia aproximada tem sido largamente utilizada em análise de séries temporais fisiológicas como ECG e EMG (Merletti, 1997; Fleisher, 1993; Goldberger). Uma tabela

multidimensional foi criada onde cada coluna representava uma variável citada acima para cada músculo estudado.

3.4.4.1 Amplitude

A amplitude do sinal EMG é o quanto ele varia no eixo Y. Geralmente características de amplitude estão relacionadas com a força da contração do músculo de forma que quanto maior a força de contração, maior o valor de amplitude (Komi e Viitasalo, 1976; Clancy e Hogan, 1999).

3.4.4.1.1 Valor Médio Quadrático (RMS)

O valor médio quadrático (RMS), calcula a média quadrática que chamamos de magnitude do sinal. O RMS é calculado utilizando a Equação 4.1 onde N representa o número de amostras da janela e m é a m-ésima amostra:

$$\text{bsp_RMS} = \sqrt{\frac{1}{N} \sum_{m=1}^N X_m^2} \quad (4.1)$$

3.4.4.1.2 Valor médio absoluto (MAV)

O valor médio absoluto (MAV), calcula o valor médio de cada valor absoluto das amostras na janela. O MAV é calculado utilizando a Equação 4.2 onde N representa o número de amostras da janela e m representa a m-ésima amostra do sinal:

$$\text{bsp_MAV} = \frac{1}{N} \sum_{m=1}^N |X_m| \quad (4.2)$$

3.4.4.1.3 Primeira e segunda derivada do valor médio absoluto (MAVFD e MAVSD)

O *Mean Absolute Value First Derivation* (MAVFD) é uma derivada ponto a ponto dos valores MAV para que se possa avaliar se existe uma variação do coeficiente angular do sinal. O MAVSD é uma segunda derivada desses valores.

3.4.4.1.4 Valor de pico

A função de pico calcula qual foi o maior valor atingido pela amplitude dentro da janela. Vale dizer que a função *peak* leva em consideração somente os valores positivos da janela. A função é calculada com a seguinte equação:

$$\text{bsp_peak} = \max(X) \quad (4.3)$$

3.4.4.2 Frequência

A frequência de um sinal representa quantas vezes um sinal se repete ao longo do tempo. No caso de um sinal estacionário, um ciclo é completo quando o sinal sai do ponto de repouso, atinge seu valor máximo, diminui até atingir seu valor mínimo e retorna até a sua posição de repouso. O sinal de eletromiografia é composto por uma somatória de vários sinais com frequências que variam em um determinado tempo (Walter et al., 2014).

3.4.4.2.1 Cruzamento por zero

Esta característica mede quantas vezes um sinal altera seus valores em volta de uma dada referência. Nesse estudo a referência é o 0 e essa função calcula quantas vezes o sinal EMG cruzou a linha do 0.

3.4.4.2.2 Banda de passagem

A banda de passagem é a faixa de frequências que compõem um sinal, ou seja, as frequências encontradas no sinal estão entre os limites inferiores e superiores da minha banda de passagem na qual a variação máxima do espectro de frequência não ultrapasse 3dB. A banda de passagem é calculada como sendo a maior frequência da banda menos a menor frequência:

$$BP = fh - fl \quad (4.4)$$

fh representa a maior frequência da banda e fl a menor frequência da banda.

Dentro da banda de passagem podemos extrair características como a maior frequência da banda, a menor frequência da banda, a frequência modal, a frequência mediana e a frequência média. Observando o espectro de frequências, a maior frequência

da banda é aquela que possui o maior valor, a menor frequência é a que possui o menor valor, a frequência mediana é o ponto médio entre a maior e a menor frequência, a frequência modal é a frequência que mais interfere dentro do espectro e a frequência média é valor médio calculado dentro do espectro de frequências.

3.4.4.3 Entropia

Chamado de mensurador de caos do sinal, a entropia tem sido utilizada em diversas pesquisas envolvendo processamento de sinais biomédicos. A entropia mede o quão caótico é um determinado sinal. Uma senóide apresenta uma entropia baixa pois seu sinal é bem ordenado. Um sinal caótico apresenta um valor alto de entropia.

3.4.4.3.1 Entropia aproximada (ApEn)

Para se calcular a entropia aproximada (ApEn) do sinal, é necessário dividir o sinal em pequenas janelas e se comparar a similaridade entre elas. Por exemplo pegamos um trecho do sinal de tamanho m e comparamos um outro trecho do sinal de tamanho m que é posterior ao primeiro trecho utilizando um parâmetro r com um valor de tolerância de 20% do desvio padrão.

A Equação 4.5 representa como foi feito o cálculo da ApEn para os sinais utilizados neste estudo onde $C_m(r)$ é a quantidade de vezes que o valor r foi ultrapassado quando calculada a distância Euclideana entre as janelas. Nesta análise, o valor de r foi estipulado como 2. A componente $C_{m+1}(r)$ é o trecho seguinte, porém com o mesmo tamanho do trecho anterior.

$$ApEn = \ln \frac{C_m(r)}{C_{m+1}(r)} \quad (4.5)$$

3.4.4.3.2 Entropia fuzzy (FuzEn)

A entropia fuzzy (FuzEn) evita que ocorra repetição na comparação entre as janelas evitando assim que ocorra redundância. A FuzEn se diferencia da ApEn na hora de decidir se a distância entre as janelas está dentro do valor de tolerância ou não. Essa decisão, que anteriormente apresentava apenas dois estados, maior ou menor, agora é feita através da aplicação do valor da distância em uma função membro, que no caso deste estudo, foi utilizada a função Gaussiana. Neste caso, o parâmetro r de tolerância passa a definir a largura da função Gaussiana.

3.4.5 Normalização dos dados

Existem várias formas de se normalizar dados hoje na área de engenharia biomédica. O método escolhido para esse estudo foi o Zscore. O Zscore é uma medida de dispersão que mede o quanto os dados se afastam do seu desvio padrão. Os dados são normalizados utilizando a Equação 4.6:

$$Z_i = \frac{x_i - x_\mu}{\varphi} \quad (4.6)$$

Z_i representa o valor do zscore da variável i ; x_i é o valor da variável i ; x_μ é a média de X ; φ é o desvio padrão de X .

3.4.6 Seleção de características

Como não se sabe a priori quais os conjuntos de dados eram mais relevantes para este estudo, muitas características foram extraídas do sinal e posteriormente um algoritmo de seleção de características foi implementado para selecionar quais as características são mais relevantes para este estudo. Um grande conjunto de características não necessariamente pode ajudar a resolver um dado problema. Além de aumentar o tempo para o processamento dos dados, um grande conjunto de características pode apresentar valores redundantes ou até mesmo insignificantes para o problema em mãos. Dessa forma o algoritmo busca um conjunto menor dentro de um grande conjunto de características que melhor apresente resultados na hora de processar aqueles dados. A Figura 17 mostra o diagrama do algoritmo de seleção de características:

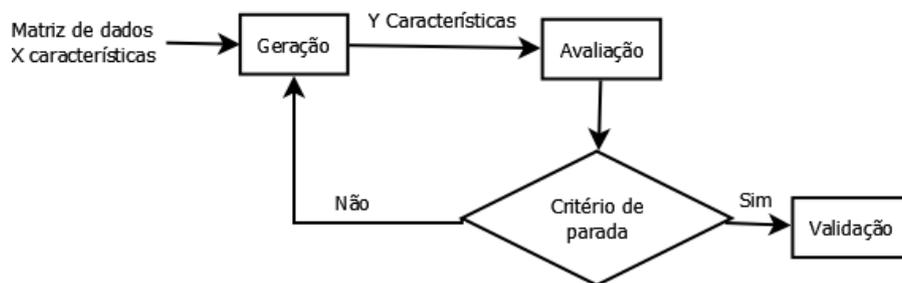


Figura 17: Diagrama do algoritmo de seleção de características.

O método utilizado neste estudo para a seleção de características foi o método Clássico (Dash et al., 1997). Este método extrai um conjunto Y de características de uma matriz de X características onde $X > Y$. O algoritmo escolhe aleatoriamente um conjunto de características e testa essas características dentro do classificador e salva a taxa de

acerto produzida com aquele conjunto de dados. Em seguida um novo conjunto de características é formado e o processo é repetido novamente. A escolha do critério de parada é muito importante, pois sem a escolha adequada, um algoritmo pode rodar exaustivamente e nunca chegar a um resultado. O critério de parada do algoritmo é um número Z de interações. Para este trabalho foi escolhido 1000 iterações. O algoritmo roda a primeira vez e armazena os resultados produzidos com aquelas características. Caso os resultados produzidos pelo segundo conjunto de características for superior, o primeiro resultado é descartado e o algoritmo retorna após o critério de parada somente quais foram as características que produziram a melhor taxa de acertos. Para os testes foi utilizado o método *k-fold cross-validation* com $k = 10$, onde um conjunto de dados é dividido em 10 subconjuntos e 90% dos dados são utilizados para o treinamento da rede e os outros 10% para testes. Neste estudo para a geração do algoritmo de seleção de características foi utilizado o *software R* com as bibliotecas *caret* e *fscaret*.

3.4.7 Support Vector Machine

O classificador Support Vector Machine (SVM) é uma poderosa ferramenta de classificação e tem sido muito utilizado dentro da área de engenharia biomédica. O SVM é utilizado para classificar dados em 2 diferentes classes por meio de um hiperplano posicionado entre dois conjuntos de dados de forma que a distância entre esses conjuntos de dados é maximizada (Bitzer e Van Der Smagt, 2006). Como neste estudo desejamos separar os dados em apenas 2 classes, o classificador SVM se mostrou uma forte ferramenta a ser testada.

Quando se tem um conjunto bidimensional de dados, a divisão dos dados pode ser facilmente vista ao se plotar esses dados em um plano. Neste estudo, as características resultantes do algoritmo de seleção de características é um conjunto de dados multidimensionais. Foi inicialmente utilizada a técnica PCA para se reduzir a dimensão desses dados de forma que fosse possível plotar esses dados em um plano e traçar o hiperplano que separasse as duas classes de dados, porém a taxa de acertos do classificador diminuiu muito então os dados utilizados para o treinamento e teste do classificador foram os dados sugeridos pelo algoritmo de seleção de características.

Para utilizar o SVM foi necessário treinar o classificador e fazer a validação cruzada do mesmo. Para isso, um conjunto de dados é utilizado para o treinamento e um outro conjunto de dados que não fez parte do treinamento é utilizado para testes, assim como feito na fase de seleção de características (Hsu et al., 2003).

Como nesse estudo os dados são multidimensionais é necessário utilizar uma função Kernel que torna possível fazer a separação de dados que podem ou não ser linearmente separados. Para que isso seja feito, inicialmente é necessário criar uma matriz que constitui as classes, e uma função de Kernel (Smola e Schölkopf, 1998). Como não se sabe qual função Kernel era mais apropriada para este estudo, foram testadas três funções Kernel: linear, radial e polinomial. Para cada músculo estudado foi utilizado um classificador SVM com cada Kernel para que se pudesse estabelecer qual o melhor método para se classificar indivíduos com hanseníase e saudáveis utilizando os diferentes músculos da face.

Nesta pesquisa, para treinamento e construção do modelo utilizado na classificação SVM foi utilizada a biblioteca de nome *e1071* do *software R*. Esta biblioteca utiliza o conjunto de dados de treinamento para gerar um modelo que então é utilizado para prever a qual classe pertence os dados do conjunto de testes. Para o treinamento de rede, um algoritmo foi gerado que separava os dados em grupo de testes e grupo de treinamento e testava aquela combinação. A divisão que gerou os melhores resultados foram 2/3 dos dados para treinamento da rede e 1/3 para testes.

3.5 Análise estatística

Para avaliarmos estatisticamente o desempenho do classificador definido para discriminar os dados coletados é necessário fazer o cálculo de algumas variáveis do sistema, tais como a sensibilidade, especificidade, precisão e acurácia (Bitzer e Van Der Smagt, 2006; Shenoy *et al.*, 2008).

3.5.1 Matriz 2x2

Para se identificar o sucesso do método, foram utilizadas as medidas de sensibilidade (S), especificidade (E), acurácia (A) e precisão (P) do classificador que são resultados dos Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN) disponibilizados em uma matriz 2x2.

Verdadeiro Positivo é o dado que pertence a classe 1 e que o classificador identificou como sendo da classe 1. Verdadeiro Negativo é o dado que pertence a classe 2 e que o classificador identificou como sendo da classe 2. Falso Negativo é o dado pertencente a classe 1 e que o classificador identificou como sendo da classe 2. Falso Positivo é o dado que pertence a classe 2 e que o classificador identificou como sendo da classe 1. A Tabela 1 mostra a disposição das variáveis VP, VN, FP e FN:

	Previsto	
Classe	1	2
1	VP	FN
2	FP	VN

Figura 18: Forma que o classificador apresenta os resultados.

3.5.2 Sensibilidade

A sensibilidade reflete a eficiência do classificador em identificar se os dados foram classificados corretamente. Uma sensibilidade alta significa que o método é eficiente em identificar se uma variável aleatória foi classificada na sua classe corretamente. A sensibilidade é calculada da seguinte forma:

$$\text{Sensibilidade} = \frac{VP}{VP+FN} \quad (4.6)$$

4.5.3 Especificidade

A especificidade representa a capacidade do classificador de determinar de forma correta, variáveis que não pertencem a uma determinada classe. Uma especificidade alta diz que o classificador consegue dizer de forma eficiente que uma variável aleatória não pertence a uma determinada classe. A especificidade é calculada da seguinte forma:

$$\text{Especificidade} = \frac{VN}{FP+VN} \quad (4.7)$$

4.5.4 Acurácia

A acurácia representa quanto dos dados foram classificados de forma correta, ou seja, a taxa de sucesso do classificador. Uma acurácia alta quer dizer que o sistema está conseguindo classificar as variáveis nas classes corretas. A acurácia é calculada da seguinte forma:

$$\text{Acurácia} = \frac{VP+VN}{VP+VN+FP+FN} \quad (4.8)$$

4.5.5 Precisão

A precisão representa o quanto as previsões do classificador foram constantes para uma determinada classe. Um valor alto de precisão não representa necessariamente que o classificador é eficiente, mas sim o quanto um determinado resultado foi repetido. A precisão é calculada da seguinte forma:

$$\text{Precisão} = \frac{VP}{VP+FP} \quad (4.9)$$

Capítulo 4

4. RESULTADOS

Para que se pudesse ver o resultado das atividades produzidas pelos participantes, os dados foram normalizados utilizando a técnica Z-score e foi utilizada a técnica PCA para reduzir a dimensão dos dados e ainda assim manter uma representação fiel dos dados. Utilizando as componentes 1 e 2 do PCA, foi plotado um gráfico que demonstra as atividades realizadas pelos participantes.

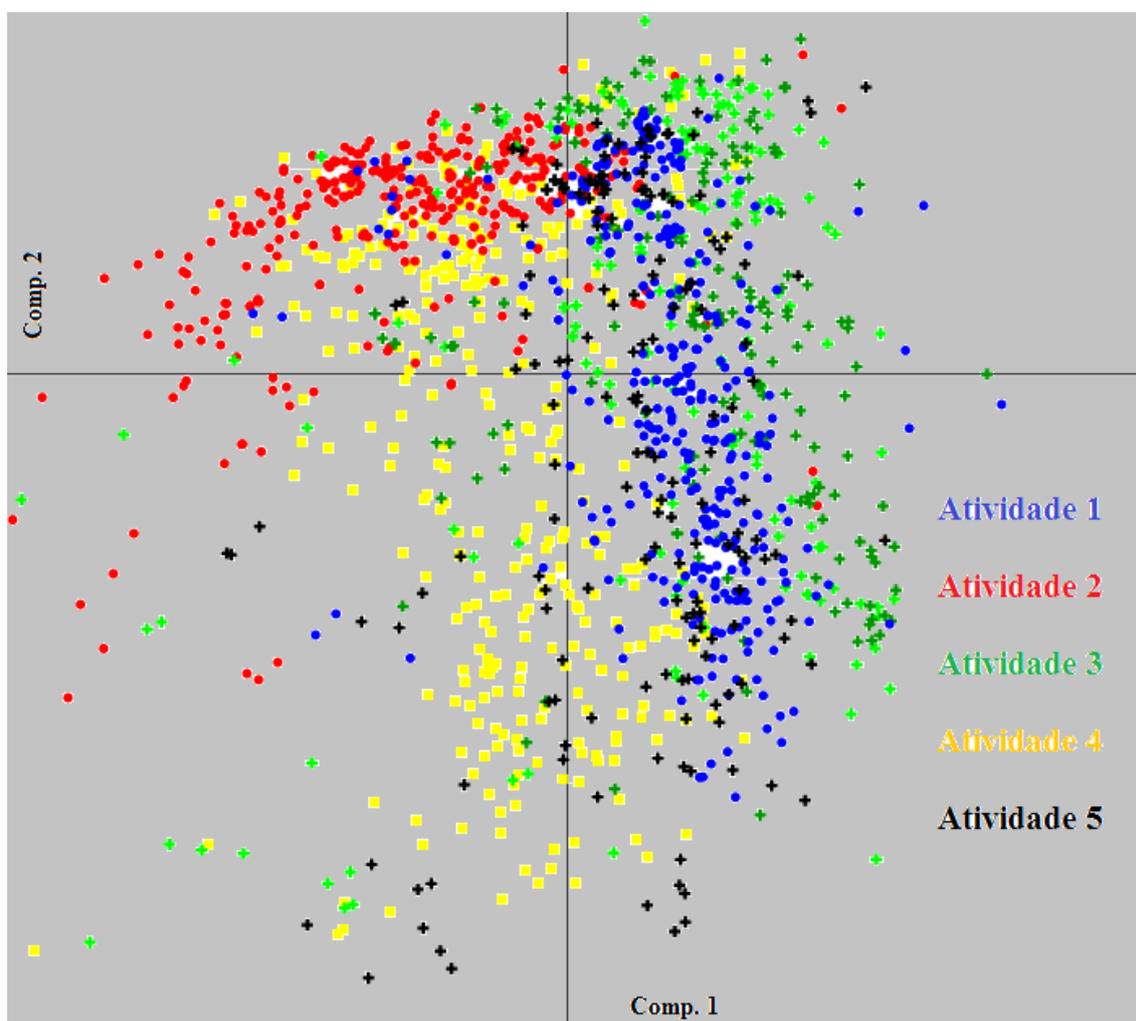


Figura 19: Gráfico das atividades realizadas pelos participantes da pesquisa utilizando o PCA.

Pela Figura 19 é possível ver o quanto as atividades se distinguem uma das outras. Para gerar esse gráfico, foi utilizado os dados extraídos do G1 e do G2.

Cada atividade plotada na Figura 19, representa a ativação de um músculo. A Atividade 1 representa a ativação do músculo frontal, a Atividade 2 representa a ativação

do músculo orbicular dos olhos, a Atividade 3 representa a ativação do músculo zigomático, a Atividade 4 representa a ativação do masseter e a Atividade 5 representa a ativação do músculo orbicular da boca.

As características escolhidas pelo algoritmo de seleção de características foram todas as características de frequência e amplitude do sinal de amplitude instantânea e todas as características de amplitude e entropia do sinal de frequência instantânea.

A Figura 20 mostra o gráfico de pontos de uma das características escolhidas pela seleção de características. A característica escolhida apresentada é a entropia aproximada do sinal de frequência instantânea. Os pontos sobre o número 1 representam a variação da entropia aproximada do G1 e os pontos sobre o número 2 representam a variação da entropia aproximada do G2.

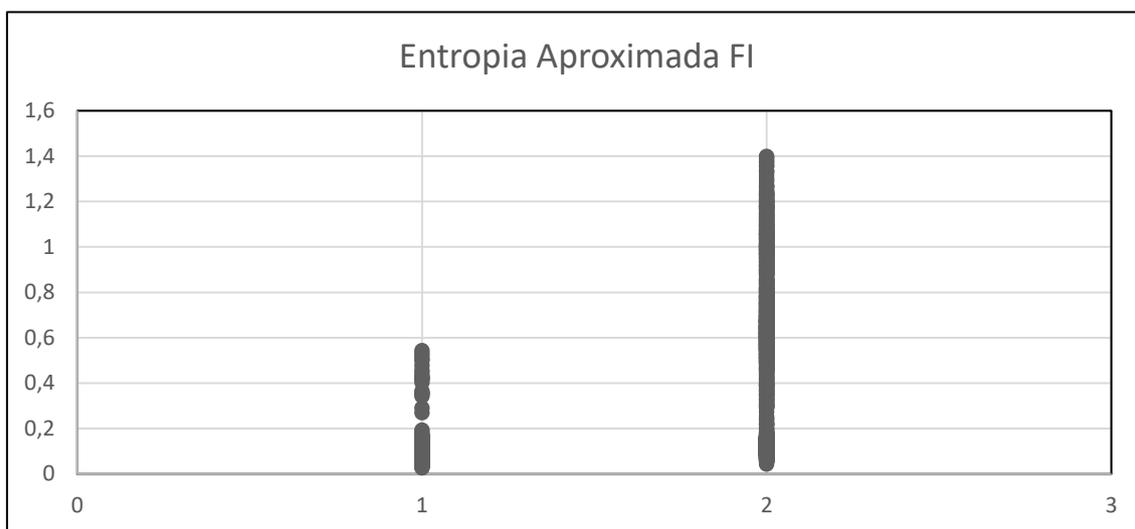


Figura 20: Gráfico de pontos de uma das características escolhidas pelo algoritmo de seleção de características

Uma das características rejeitadas pelo algoritmo de seleção de características foi a entropia aproximada do sinal filtrado. A Figura 21 mostra o gráfico de pontos dessa característica.

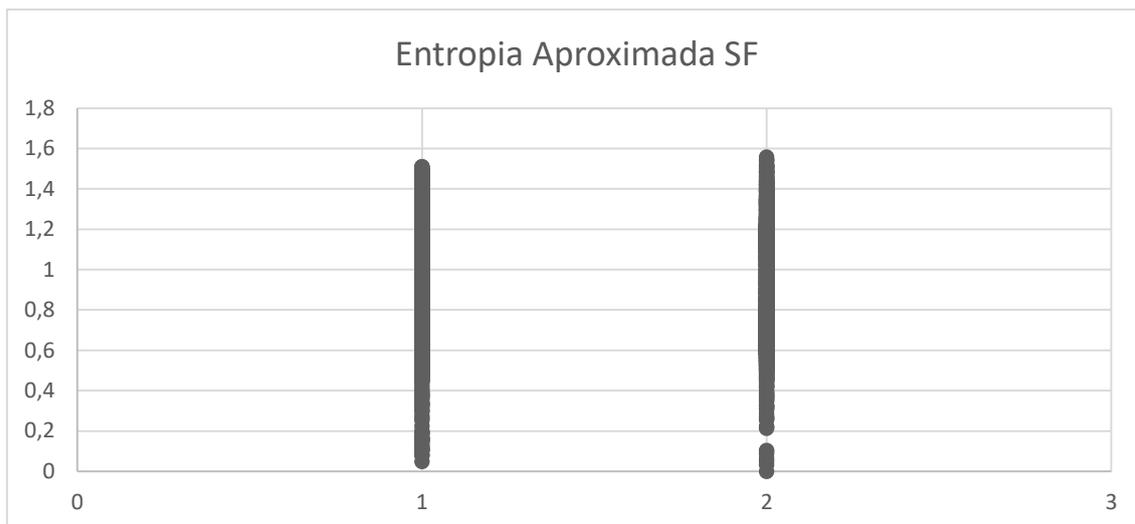


Figura 21: Gráfico de pontos de uma das características rejeitadas pelo algoritmo de seleção de características.

As tabelas a seguir correspondem ao cálculo das variáveis de desempenho (precisão, sensibilidade, especificidade e acurácia) estipuladas para cada músculo e para cada Kernel. Cada tabela corresponde a um músculo.

Tabela 01: Masseter esquerdo com Kernel linear.

Masseter Esquerdo					
Linear	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	7	3	0,85	0,16
2	0	10			

Tabela 02: Masseter direito com Kernel linear.

Masseter Direito					
Linear	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	6	4	0,8	0,29
2	0	10			

Tabela 03: Masseter esquerdo com Kernel radial.

Masseter Esquerdo					
Radial	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	6	4	0,8	0,14
2	0	10			

Tabela 04: Masseter direito com Kernel radial.

Radial	Masseter Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	7	3	0,85	0,15
	2	0	10		

Tabela 05: Masseter esquerdo com Kernel polinomial.

Polinomial	Masseter Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	7	3	0,85	0,14
	2	0	10		

Tabela 06: Masseter direito com Kernel polinomial.

Polinomial	Masseter Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	6	4	0,8	0,3
	2	0	10		

Tabela 07: Olho esquerdo com Kernel linear.

Linear	Orbicular do Olho Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	8	2	0,9	0,27
	2	0	10		

Tabela 08: Olho direito com Kernel linear.

Linear	Orbicular do Olho Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	10	0	0,9	0,23
	2	2	8		

Tabela 09: Olho esquerdo com Kernel radial.

Radial	Orbicular do Olho Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	10	0	0,9	0,18
	2	2	8		

Tabela 10: Olho direito com Kernel radial.

Radial	Orbicular do Olho Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	9	1	0,95	0,24
	2	0	10		

Tabela 11: Olho esquerdo com Kernel polinomial.

Polinomial	Orbicular do Olho Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	10	0	0,75	0,22
	2	5	5		

Tabela 12: Olho direito com Kernel polinomial.

Polinomial	Orbicular do Olho Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	10	0	0,6	0,21
	2	8	2		

Tabela 13: Zigomático esquerdo com Kernel linear.

Linear	Zigomatico Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	8	2	0,7	0,17
	2	4	6		

Tabela 14: Zigomático direito com Kernel linear.

Linear	Zigomatico Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	6	4	0,75	0,21
	2	1	9		

Tabela 15: Zigomático esquerdo com Kernel radial

Radial	Zigomatico Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	8	2	0,7	0,15
	2	4	6		

Tabela 16: Zigomático direito com Kernel radial

Radial	Zigomatico Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	4	6	0,7	0,13
	2	0	10		

Tabela 17: Zigomático esquerdo com Kernel polinomial

Polinomial	Zigomatico Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	8	2	0,6	0,17
	2	6	4		

Tabela 18: Zigomático direito com Kernel polinomial.

Polinomial	Zigomatico Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	10	0	0,7	0,14
	2	6	4		

Tabela 19: Frontal esquerdo com Kernel linear.

Linear	Frontal Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	10	0	0,8	0,16
	2	4	6		

Tabela 20: Frontal direito com Kernel linear.

Linear	Frontal Direito				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	6	4	0,65	0,2
	2	3	7		

Tabela 21: Frontal esquerdo com Kernel radial.

Radial	Frontal Esquerdo				
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada
		1	2		
	1	10	0	0,8	0,2
	2	4	6		

Tabela 22: Frontal direito com Kernel radial

Radial	Frontal Direito					
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada	
		1	2			
	1	6	4	0,65	0,21	
	2	3	7			

Tabela 23: Frontal esquerdo com Kernel polinomial.

Polinomial	Frontal Esquerdo					
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada	
		1	2			
	1	10	0	0,75	0,17	
	2	5	5			

Tabela 24: Frontal direito com Kernel polinomial

Polinomial	Frontal Direito					
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada	
		1	2			
	1	10	0	0,7	0,18	
	2	6	4			

Tabela 25: Orbicular da boca com Kernel linear.

Linear	Orbicular da Boca					
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada	
		1	2			
	1	10	0	0,85	0,34	
	2	3	7			

Tabela 26: Orbicular da boca com Kernel radial.

Radial	Orbicular da Boca					
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada	
		1	2			
	1	10	0	1	0,41	
	2	0	10			

Tabela 27: Orbicular da boca com Kernel polinomial

Polinomial	Orbicular da Boca					
	Classe	Previsto		Taxa de acerto	Erro de validação cruzada	
		1	2			
	1	10	0	0,9	0,41	
	2	2	8			

Para cada músculo mostrado foi calculado a sensibilidade, especificidade, acurácia e precisão. Os resultados estão mostrados nas Figuras 20, 21 e 22. As siglas mostradas nas Figuras 20, 21 e 22 correspondem a:

ME: masseter esquerdo;

MD: masseter direito;

OE: orbicular do olho esquerdo;

OD: orbicular do olho direito;

ZE: zigomático esquerdo;

ZD: zigomático direito;

FE: frontal esquerdo;

FD: frontal direito;

B: orbicular da boca.

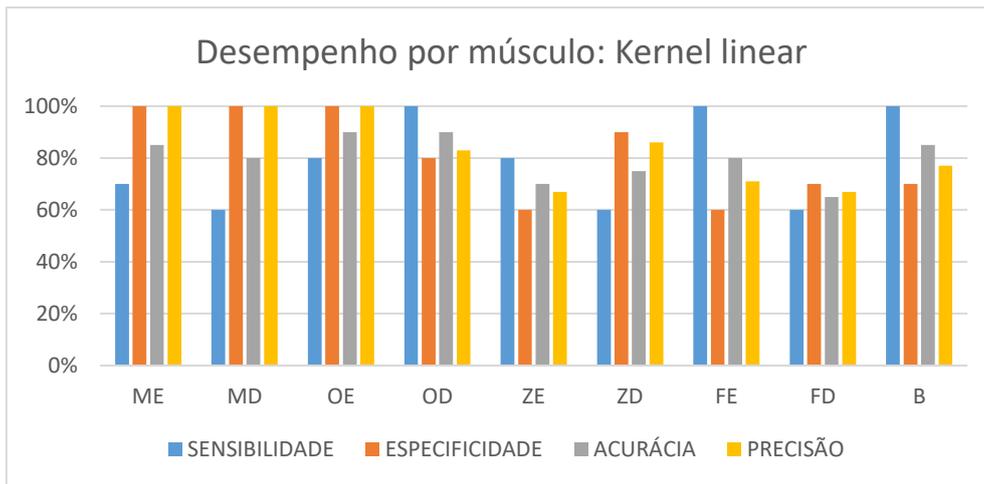


Figura 22: Desempenho de todos os músculos utilizando SVM com Kernel linear.

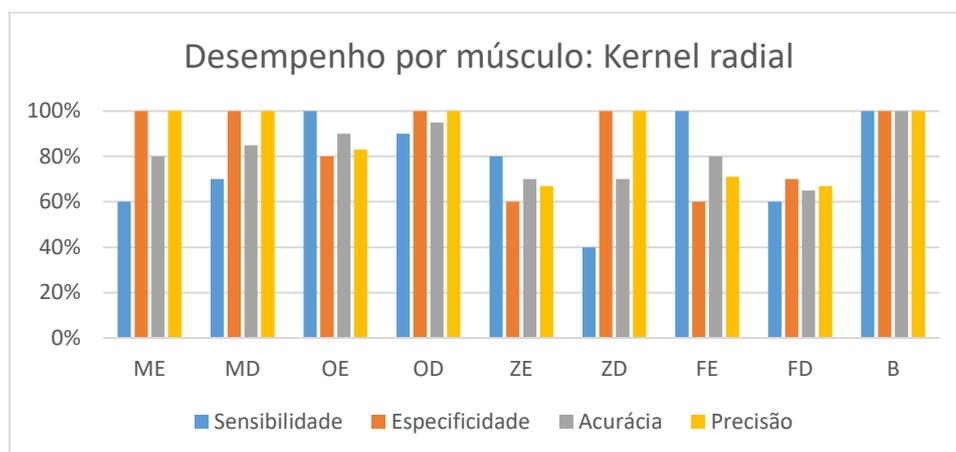


Figura 23: Desempenho de todos os músculos utilizando SVM com Kernel radial.

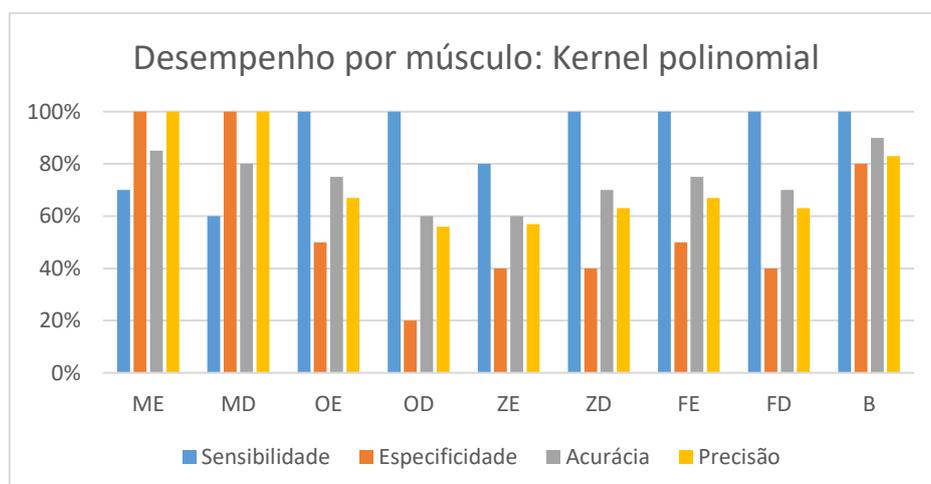


Figura 24: Desempenho de todos os músculos utilizando SVM com Kernel polinomial

Capítulo 5

5. CONSIDERAÇÕES FINAIS

5.1 Discussão

Os eletrodos descartáveis disponíveis no mercado, mesmo os que são feitos para crianças ainda apresentam um tamanho que não é adequado para serem utilizados nos músculos face. Existem no mercado hoje, eletrodos a seco que possuem um tamanho reduzido, porém quando se trabalha com uma patologia em que existe o risco de infecção, este método deixa de ser adequado. O corte da área em volta do núcleo do eletrodo descartável possibilitou a captação dos sinais eletromiográficos nos músculos da face de forma eficiente, porém gerando o problema de que eles não conseguiam aderir a superfície do rosto devido à ação da gravidade. A eletromiografia de superfície oferece uma grande vantagem por ser um método não invasivo e que possibilita analisar os sinais de músculos e nervos sem causar dor ao participante da pesquisa. Colocar o participante da pesquisa na posição decúbito dorsal não só oferece maior conforto para o participante como também diminui o efeito da gravidade sobre o eletrodo, possibilitando dessa forma utilizar eletrodos descartáveis com a película recortada para o uso de eletromiografia na face em pacientes com hanseníase. Musculaturas mais profundas como a infrahióidea requerem um método diferente que a eletromiografia de superfície pois o sinal coletado não apresentou uma boa relação sinal/ruído devido ao fato que a eletromiografia está limitada ao sinal que pode ser captado pela superfície da pele.

Como a priori não se sabe de forma conclusiva se os músculos da face são de fato afetados pela hanseníase ou como são afetados, buscou-se extrair características que abordassem todos os pontos possíveis como frequência, amplitude e aleatoriedade. O algoritmo de seleção de características mostrou que para a classificação entre pacientes com hanseníase e pacientes saudáveis, uma combinação das características do sinal de amplitude instantânea e frequência instantânea obteve uma taxa de acerto maior. Uma taxa de acertos maior pode indicar que aquele músculo está sendo mais afetado pela ação do *M. leprae*. Músculos como o frontal que tiveram uma taxa de acertos baixa (menor que 70%) talvez possam apresentar uma taxa de acertos maior utilizando um diferente método, porém os dados mostram o método é capaz de mostrar que a ação do *M. leprae*

tem sido mais intensa no músculo orbicular dos olhos do que no frontal e isso está conforme o encontrado na literatura.

Na utilização de todas as características ao mesmo tempo, apesar de o processo não necessitar de uma capacidade de processamento maior, os resultados foram piores. Os resultados produzidos pelo classificador utilizando todas as características foram desconsiderados pela baixa taxa de acerto. Isso acontece porque como dito anteriormente, não se sabe de que forma a hanseníase afeta os músculos dos pacientes e algumas características podem gerar resultados redundantes ou não influenciar de forma nenhuma. O processo de seleção de características foi fundamental para o aprimoramento do método utilizado pois quando se utilizou todas as características obtidas, o classificador apresentou uma taxa de acerto menor que aquela apresentada com as características escolhidas pelo algoritmo de seleção de características. As características escolhidas foram: do sinal de amplitude instantânea: RMS, MAV, MAVFD, MAVSD, PEAK, F+, F-, Fmean, Fmod; do sinal de frequência instantânea foram: RMS, PEAK, MAVFD e MAVSD e PEAK.

Para se garantir que a coleta de dados foi feita corretamente, foi utilizada a técnica PCA e plotado um gráfico de pontos cada atividade em cores diferentes utilizando as componentes 1 e 2 do PCA, em que cada ponto representa uma atividade feita por um indivíduo. A Figura 19 mostra que as atividades se agrupam demonstrando assim a distinção entre elas com exceção da Atividade 5. Isso prova que a coleta de dados foi bem feita e que existe uma distinção entre os diferentes movimentos faciais estudados nesse trabalho. Um mesmo movimento facial pode apresentar atividade mioelétrica em vários músculos, porém o sinal visto em todos os músculos está ligado a atividade que o participante está executando e não ao músculo em si. O músculo zigomático apresenta sinais distintos quando o participante está realizando a Atividade 3 e quando realiza a Atividade 4. O mesmo acontece nos outros músculos. O sinal captado no músculo é resultado da atividade realizada e não do músculo em si, ou seja, pode-se captar sinais com características diferentes no mesmo músculo.

Classificadores SVM oferecem a vantagem da utilização de uma função Kernel (Xu et al., 2010). Como não se pode plotar os dados em um plano, pois os dados possuem muitas dimensões, foi necessário utilizar vários métodos diferentes para se ver qual produzia o melhor resultado. Não se obteve uma predominância de um tipo de Kernel

sobre o outro. Cada músculo apresentou uma taxa de acerto maior utilizando um tipo de Kernel. Devido ao fato do classificador necessitar que uma amostra dos dados seja retirada para o treinamento e criação de um modelo que então é utilizado no restante dos dados, poucos dados foram utilizados para o teste do classificador e quando ocorre a diferença entre 1 acerto de um modelo para outro a diferença na taxa de acertos é de aproximadamente 5%. No caso de um evento raro estar acontecendo, provavelmente não será notado devido ao estudo apresentar um número de participantes baixo. Com tudo, o objeto desse estudo era encontrar um método que fosse capaz de apontar qual músculo e movimento facial são mais adequados para se diferenciar o grupo controle do grupo com hanseníase. Os resultados mostram que o método pode ser utilizado para encontrar eventos que estejam acontecendo no G2. Caso se esteja procurando por um evento raro, o método pode ser aplicado, porém utilizando um número de participantes maior.

O músculo masseter não apresentou uma grande diferença quando comparado os 3 tipos de Kernel. O masseter esquerdo apresentou um acerto a menos utilizando o Kernel Radial quando comparado com os Kernels linear e polinomial. A especificidade mostra que houve um acerto de 7 indivíduos saudáveis para os Kernels Linear e polinomial e um acerto de 6 indivíduos saudáveis com o Kernel Radial. O masseter direito obteve resultados semelhantes, porém com o Kernel radial apresentado um acerto a mais que os outros dois Kernels de indivíduos saudáveis. Essa diferença estatística parece ser grande devido ao pequeno número de indivíduos usados para teste. Acredita-se que um n maior não mostrará diferença significativa entre os 3 modelos de Kernel.

O músculo orbicular dos olhos apresentou uma maior diferença quando comparado os 3 tipos de Kernel. O Kernel polinomial apresentou uma taxa de acertos baixa quando comparado com o linear e o radial. A diferença vista entre o Kernel radial e linear pode ser explicada mais uma vez pelo pequeno número de indivíduos para teste do classificador. Acredita-se que não há diferença significativa entre os Kernels linear e radial quando utilizado os dados do músculo orbicular dos olhos. Uma taxa de acertos alta para os músculos orbicular dos olhos direito e esquerdo evidenciam que a ação do *M. leprae* está sendo mais intensa naquela região. Esta ação está de acordo com a literatura que demonstra que em muitos casos, pessoas com hanseníase apresentam lagoftamo, que é uma diminuição na força dessa musculatura.

O músculo zigomático obteve as taxas de acerto mais baixas entre todos os músculos analisados neste estudo. Pode-se notar que tanto para o zigomático direito quanto para o zigomático esquerdo, a diferença na taxa de acerto dos 3 Kernels é de apenas 1 indivíduo. A especificidade utilizando o Kernel polinomial foi mais baixa tanto para o zigomático direito como o esquerdo, por isso considera-se que os Kernels linear e radial são mais adequados para a análise desses dados.

O músculo frontal obteve a maior disparidade entre os músculos analisados nesse estudo quando comparado o lado esquerdo com o lado direito. Olhando para o Kernel polinomial podemos ver que a sensibilidade é de 100% tanto para o frontal esquerdo quanto para o direito. Isso quer dizer que o classificador classificou corretamente todos os indivíduos saudáveis. A especificidade é baixa tanto para o frontal esquerdo quanto para o direito, demonstrando que o classificador teve problemas para classificar os indivíduos do G2. Esses dados podem evidenciar que a ação do *M. leprae* está causando uma disparidade na contração dos músculo frontal direito com o frontal esquerdo.

O músculo orbicular da boca apresentou resultados perfeitos quando utilizado o Kernel radial. Como em nenhum outro caso foi encontrado resultados como esse, deve-se questionar se este método é realmente o mais adequado para análise desse músculo e testes com um número maior de indivíduos devem ser feitos, no entanto esse resultado aparenta ser muito positivo visto que o objetivo deste estudo é encontrar o melhor método para avaliar cara músculo da face.

6.2 Conclusão

A Figura 19 mostra que a adaptação nos eletrodos e o protocolo estabelecido para a coleta de dados de eletromiografia da face teve bons resultados e pode ser repetido em diferentes doenças quando o objetivo for a coleta de dados de eletromiografia da face.

Pela Figura 19 é possível ver que há uma distinção entre as Atividades 1, 2, 3 e 4. A Atividade 5 não apresentou um padrão com os participantes dessa pesquisa, ocupando toda a área do gráfico.

Neste estudo buscou-se encontrar o melhor método para avaliar os dados coletados de eletromiografia da face em pacientes com hanseníase. Mesmo com a capacidade alta de processamento de dados dos computadores atualmente, é necessário quando não se sabe quais características são mais relevantes para o estudo, uma seleção

das características em estudo para se maximizar a eficiência do classificador. Uma combinação das características extraídas do sinal de amplitude e frequência instantânea mostraram ser as características que produziam melhores resultados no classificador SVM.

Os músculos que mostraram melhores resultados foram os músculos orbicular da boca e orbicular da boca. O músculo frontal apresentou uma disparidade grande entre direito e esquerdo e uma taxa de acertos baixa quando comparado aos demais músculos. O músculo zigomático apresentou uma taxa de acertos mais baixa quando comparado com os outros músculos. Os resultados evidenciam que a ação do *M. leprae* se concentra mais nos músculos orbiculares do olhos, que são músculos mais frios que o músculo zigomático

Apesar da técnica PCA ser largamente utilizada na área de engenharia biomédica atualmente, esta técnica se mostrou ineficiente para os dados que seriam usados no classificador SVM. As características resultantes do algoritmo de seleção de características apresentaram um resultado melhor que o PCA feito nessas mesmas características. Também pode-se concluir que devido a multidimensionalidade dos dados, não se pode plotar os gráficos em um plano e os dados mostram que cada músculo oferece resultados diferentes com diferentes tipos de Kernel e a escolha do Kernel adequado pode mudar significativamente a taxa de acertos do classificador. Para o músculo orbicular dos olhos a escolha certa do Kernel pode ser a diferença entre uma taxa de acertos acima de 90% e menos que 80%.

6.3 Trabalhos futuros

Esta pesquisa foi realizada com o intuito de encontrar o melhor método para se captar sinais de eletromiografia da face em pacientes com hanseníase e para se avaliar quais músculos podem ser utilizados para a diferenciação entre indivíduos saudáveis e com hanseníase. Concluiu-se que a eletromiografia e um classificador SVM com o Kernel adequado podem ajudar de forma eficiente a classificar indivíduos saudáveis e com hanseníase.

Sugere-se para trabalhos futuros aplicar os métodos e conclusões encontradas neste trabalho em estudos com diferentes patologias que possam vir a influenciar a musculatura facial. É interessante ainda um estudo que utilize outros tipos de

classificadores que sejam capazes de classificar variáveis aleatórias em mais de duas classes para se tentar identificar se é possível classificar as diferentes formas clínicas de hanseníase.

REFERÊNCIAS

- ANDRADE, A. O. **Decomposition and analysis of electromyographic signals**. 2005. Tese (Doutorado em Cybernetics. University of Reading, UR, Inglaterra).
- ARAÚJO, M.G. Hanseníase no Brail. *Revista da Sociedade Brasileira de Medicina Tropical*. 2003; 36(3):373-382.
- ATKINS, C. M.; CHEN, S. J.; KLANN, E.; SWEAT, J. D. Increased phosphorylation of myelin basic protein during hippocampal long-term potentiation. *J Neurochem*. 1997;68:1960–1967.
- AYUSO, T. e JERICO, I. Emergencies in neuromuscular pathology. *Anales Sis San Navarra [online]*. 2008, vol.31, suppl.1, pp. 115-126.
- BASMAJIAN, J. V. *Muscles Alive. Their Functions Revealed by Electromyography*. *Academic Medicine*, v. 37, n. 8, p 802, 1962. ISSN 1040-2446
- BERNARDES, D.F.F; GOMEZ, M.V.S.G.; BENTO, R.F. Surface electromyography in peripheral facial paralysis patients. *Rev. CEFAC*. 2010 Jan-Fev; 12(1):91-96.
- BITZER, S.; VAN DER SMAGT, P. Learning EMG control of a robotic hand: towards active prostheses. *Robotics and Automation, 2006. ICRA 2006. Proceedings 2006 IEEE International Conference on, 2006, IEEE*. p.2819-2823.
- BOUASHASH, B. Estimating and interpreting the instantaneous frequency of a signal – part 1: fundamentals. 1992.
- CLANCY, E.; HOGAN, N. Probability density of the surface electromyogram and its relation to amplitude detectors. ***Biomedical Engineering, IEEE Transactions on***, v. 46, n. 6, p. 730-739, 1999. ISSN 0018-9294.
- COMI, G.; FILIPPI, M.; MARTINELLI, V.; SIRABIAN, G.; VISCIANI, A.; CAMPI, A. Brain magnetic resonance imaging correlates of cognitive impairment in multiple sclerosis. *J Neurol Sci*. 1993;115(Suppl):S66–S73.
- DA SILVA, H. J. *Protocolo de eletromiografia de superfície em fonoaudiologia*. Barueri-SP: Pró-Fono, 2013.

DASH, M., LIU H. Feature Selection for Classification. *Intelligent Data Analysis 1* (1997) 131–156

DE LUCA, C. Electromyography Encyclopedia of Medical Devices and Instrumentation. **John Wiley Publisher**, 2006.

DE LUCA, C. J. et al. Filtering the surface EMG signal: Movement artifact and baseline noise contamination. **Journal of biomechanics**, v. 43, n. 8, p. 1573-1579, 2010. ISSN 0021-9290.

DHAR, S., SHARMA, V.K., KAUR, S. Facial, glossopharyngeal, vagus and hypoglossal nerve palsy in case of lepromatous leprosy. *Indian J Dermatol.* 1993;65(3):333-6.

FLEISHER, L. A., PINCUS, S. M., ROSENBAUM, S. H. Approximate entropy of heart rate as a correlate of postoperative ventricular dysfunction. *Anesthesiology* 78: 683–692, 1993.

FOSTER, K. R., KOPROWSKI R., SKUFCA J. D. Machine learning, medical diagnosis, and biomedical engineering research. **DOI:** 10.1186/1475-925X-13-94. 2014.

FURLAN, R. M. M. M.; REZENDE, B. A.; MOTTA, A. R.. Comparison of the electric activity of the suprahyoid muscles during different lingual exercises. *Audiol., Commun. Res., São Paulo* , v. 20, n. 3, p. 203-209, Sept. 2015.

GOLDERBERG, A.L., MIETUS, J. E., RIGNEY D. R., WOOD M. L., and FORTNEY, S. M. Effects of head-down bed rest on complex heart rate variability: response to LBNP testing. *J Appl Physiol* 77: 2863–2869, 1994

HSU, C.-W.; CHANG, C.-C.; LIN, C.-J. **A practical guide to support vector classification** 2003.

HUGHES, T.D. The effects of two rehabilitation exercises on submental hyolaryngeal muscular activity. 2015. 73f. Dissertation (Master of Science) - Texas Christian University, Texas.

JOLLIFE, I. *Principal Component Analysis*. New York: Springer-Verlag, 1986.

Iniciativa da União Europeia em engenharia biomédica e ciências da saúde SENIAM [acesso em 04 de julho de 2016]. Disponível em: <http://www.seniam.org/>.

FEE, J. W.; MILLER, F. (2012). A Critical Review and Proposed Improvement in the Assessment of Muscle Interactions Using Surface EMG, *EMG Methods for Evaluating Muscle and Nerve Function*, Mr. Mark Schwartz (Ed.), InTech, DOI: 10.5772/27260.

JOPLING WH & Mc DOUGALL AC. A doença. In: **Manual de hanseníase**, 4º ed, Atheneu Editora, São Paulo, p. 11-59, 1991.

KOMI, P. V.; VIITASALO, J. H. Signal characteristics of EMG at different levels of muscle tension. *Acta Physiologica Scandinavica*, v. 96, n. 2, p. 267-276, 1976. ISSN 1365-201X.

PERES, L. B.; OLIVEIRA, M. F.; QUEIROZ, C. M.; GOULART, I. M. B.; ANDRADE, A. O. “Proposta de um protocolo experimental para detecção de atividade eletromiográfica de músculos faciais em indivíduos com hanseníase”. VIII Simposio de Engenharia Biomédica. 2015.

LUKA, E. E. “Understanding the stigma of leprosy”, *SSMJ*, August, 2010, 3(3). Downloaded from www.southernsudanmedicaljournal.com.

GAZZONI, M.; FARINA, D.; MERLETTI, R. “A new method for the extraction and classification of single motor unit action potentials from surface EMG signals” *Journal of Neuroscience Methods*, 136, pp. 165–177. 2004.

LUCAS, M.F.; GAUGRIAU, A.; PASCUAL, S.; DONCARLI, C.; FARINA, D. “Multi-channel surface EMG classification using support vector machines and signal-based wavelet optimization”. *Biomedical Signal Processing and Control*. pp. 169–174. Mar. 2008.

MERLETTI, R. et al. Technology and instrumentation for detection and conditioning of the surface electromyographic signal: state of the art. *Clinical Biomechanics*, v. 24, n. 2, p. 122-134, 2009. ISSN 0268-0033.

NEYRA, J. La lepra en la biblia / Leprosy in the Bible. 1994: 7(1)65-66

OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. **Discrete-time signal processing**. Prentice-hall Englewood Cliffs, 1989.

PERNAMBUCO, L.A.; CUNHA, D.A.; SILVA, H.J. Protocolo para avaliação do sinal elétrico dos músculos masseter e suora-hióideos durante a deglutição. In: SILVA,

H.J.(Org.) Protocolos de Eletromiografia de Superfície em Fonoaudiologia. São Paulo: PróFono, 2013, cap. 2, p. 39-50.

MERLETTI, R.; LO, L. R. “Conte Surface EMG signal processing during isometric contractions”. *Journal of Electromyography and Kinesiology*, 7, pp. 241–250. Apr. 1997.

REES, R. J. W. The microbiology of leprosy. In: Hastings, R. C. *Leprosy. Medicine in the Tropics Series*. Churchill Livingstone. New York, USA. 1985. p. 31-52.

REVEL, J.; PETER, J.P. “O corpo: o homem doente e sua história”, in J. Le Goff e P. Nora, cds., *História: Novos Objetos*, Rio de Janeiro, Francisco Alves, 1988, p. 144.

RIDLEY, D.S.; JOPLING, W.H. Classification of leprosy according to immunity: a five-group system. *Int. J. Leprosy* 34:255-73, 1966

SHENOY, P. et al. Online electromyographic control of a robotic prosthesis. **Biomedical Engineering, IEEE Transactions on**, v. 55, n. 3, p. 1128-1135, 2008. ISSN 0018

SITTEL, C.; STENNERT, E. Prognostic value of electromyography in acute peripheral facial palsy. *Otol Neurotol*. 2001; 22(1):100-4.

SMOLA, A. J.; SCHÖLKOPF, B. **Learning with kernels**. Citeseer, 1998. ISBN 3884573497.

SOUZA, C. S. Hanseníase: Formas clínicas e diagnóstico diferencial. Ribeirão Preto: 1997. *Simpósio de Hanseníase* 30: 325-334.

TAN, J.; ANDRADE, A. O.; WALTER, S.; LI, H.; HRABAL, D.; RUKAVINA, S.; LIMBRECHT-ECKLUNDT, K.; TRAUE, H. C. On the use of instantaneous mean frequency estimated from the Hilbert spectrum of facial electromyography for differentiating core affects. In: 2012 5th International Conference on Biomedical Engineering and Informatics (BMEI), 2012, Chongqing. 2012 5th International Conference on BioMedical Engineering and Informatics, 2012. p. 568.

VAN BRAKEL, W.H.; NICHOLLS, P.G.; WILDER-SMITH, E.P.; DAS, L.; BARKATAKI P.; LOCKWOOD, D.N.; INFIR STUDY GROUP. Early Diagnosis of Neuropathy in Leprosy Comparing Diagnostic Tests in a Large Prospective Study (the INFIR Cohort Study). *PLoS Negl. Trop. Dis*. 2008; 2(4): e212

WALTER, S. et al. Automatic pain quantification using autonomic parameters. **Psychology & Neuroscience**, v. 7, n. 3, p. 363, 2014. ISSN 1983-3288.

XU, R.; WUNSH, D. C. Clustering Algorithms in Biomedical Research: A Review. **IEEE REVIEWS IN BIOMEDICAL ENGINEERING**, VOL. 3, 2010. Methodological Review