

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS GRADUAÇÃO EM
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Técnicas para o Reconhecimento de Padrões no Sinal
Mioelétrico.

Gabriel Cirac Mendes Souza

Itajubá, Fevereiro de 2018

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS GRADUAÇÃO EM
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Gabriel Cirac Mendes Souza

Técnicas para o Reconhecimento de Padrões no Sinal
Mioelétrico.

Dissertação submetida ao Programa de Pós-Graduação
em Ciência e Tecnologia da Computação como parte dos
requisitos para obtenção do Título de Mestre em Ciência
e Tecnologia da Computação

Área de Concentração: Sistemas de Computação

Orientador: Prof. Dr. Robson Luiz Moreno

Fevereiro de 2018

Itajubá - MG

A palavra é meu domínio sobre o mundo.

Clarice Lispector

Agradecimentos

A todos aqueles que certa forma fizeram parte dessa jornada, aos meus pais por possibilita-la e a Unifei por me ajudar a realiza-la. Uma lembrança aos professores do saudoso ICE, que me mostram que a matemática é a base de qualquer caminho. Aos professores Enzo e Thatyana, pela maneira leve a qual lecionam. Ao professor Vantuil por me ensinar o valor da resiliência. Ao professor Edmilson por mostrar que nem toda proposição é verdadeira, mas todo ensinamento implica em algum valor verdade. Ao professor Bruno pelo tratamento estatístico. Ao meu orientador Robson pela oportunidade concedida - que o seu sonho continue. A todas as pessoas as quais eu convivi e pude aprender e ensinar durante o caminho percorrido em minha querida Itajubá. Colegas de turma, projetos especiais, colegas de república e a minha querida Ju. A CAPES pelo fomento dado. Sou atento a todos.

“Veritas vos liberabit”

Gabriel Cirac Mendes Souza

Resumo

A Miografia consiste na técnica de monitoramento do sinal elétrico oriundo da contração muscular e tem sido utilizada para avaliação e diagnóstico de doenças ou problemas musculares. O sinal mioelétrico que é coletado da superfície da pele e é proveniente do comando cerebral, carrega informações sobre determinados movimentos. A partir desse sinal é possível identificar as atividades musculares, possibilitando a construção de sistemas de reabilitação para pessoas que perderam algum membro superior ou que nasceram com algum tipo de má formação. Essa dissertação apresenta um estudo geral sobre a miografia e uma avaliação de desempenho de três ferramentas de reconhecimento de padrões do sinal mioelétrico, fornecendo uma tabela de operação para cada uma delas com diversas configurações possíveis. Os seguintes classificadores para reconhecimento de padrões foram avaliados: Análise Discriminante Linear (LDA), um dos classificadores mais usados em estudos do gênero. Netlab GLM que é um método linear relativamente novo e o Netlab MLP, que utiliza redes neurais em sua arquitetura. Para o algoritmo MLP, além da avaliação feita com relação a sua performance, verificou-se a viabilidade de operação quando o mesmo era alimentado por um sinal re-amostrado com uma representação generalizada dos pontos, segundo os critérios do Teorema da Amostragem de Nyquist.

Palavras-chaves: Miografia, Redes Neurais, Prótese.

Abstract

The Myiography consists of the technique of monitoring the electrical signal coming from muscle contraction and has been used to evaluate and diagnose diseases or muscular problems. The myoelectric signal that is collected from the surface of the skin and comes from the brain, carries information about certain movements. From this signal it is possible to identify the muscular activities, enabling the construction of rehabilitation systems for people who have lost some upper limb or who were born with some type of malformation. This dissertation presents a general study on myography and a performance evaluation of three myoelectric signal pattern recognition tools, providing an operation table for each of them with several possible configurations. The following classifiers for pattern recognition were evaluated: Linear Discriminant Analysis (LDA), one of the most used classifiers in studies of the genre. Netlab GLM which is a relatively new linear method and Netlab MLP, which uses neural networks in its architecture. For the MLP algorithm, in addition to the evaluation made in relation to its performance, it was verified the viability of operation when it was fed by a re-sampled signal with a generalized representation of the points, according to the criteria of the Nyquist Sampler Theorem.

Keywords: Myography, Neural Networks, Prosthesis.

Sumário

Lista de Figuras

Lista de Tabelas

| | |
|--|-------|
| Glossário | p. 14 |
| 1 Introdução | p. 15 |
| 1.1 Análise Discriminante Linear - LDA | p. 18 |
| 1.2 Netlab MLP | p. 18 |
| 1.3 Netlab GLM | p. 19 |
| 1.4 Objetivo | p. 19 |
| 1.5 Estrutura da Dissertação | p. 20 |
| 2 O Sinal Mioelétrico | p. 22 |
| 2.1 Potencial de Ação | p. 23 |
| 2.2 Junção Neuromuscular | p. 25 |
| 2.3 Unidade Motora | p. 25 |
| 2.4 Características do Sinal Mioelétrico | p. 27 |
| 3 Classificadores | p. 30 |

| | | |
|----------|--|--------------|
| 3.1 | Reconhecimento de Padrões | p. 30 |
| 3.2 | Classificação Supervisionada | p. 32 |
| 3.3 | Classificação Não Supervisionada | p. 33 |
| 3.4 | Análise Discriminante Linear - LDA | p. 35 |
| 3.4.1 | Discriminação e Classificação | p. 35 |
| 3.5 | Perceptron Multicamadas - MLP | p. 36 |
| 3.5.1 | Processos de Aprendizado | p. 38 |
| 3.5.2 | Retropropagação | p. 40 |
| 3.6 | Modelo Linear Generalizado - GLM | p. 41 |
| 4 | Plataforma de Reconhecimento de Padrões | p. 43 |
| 4.1 | BioPatRec | p. 43 |
| 4.2 | Gravação do Sinal | p. 44 |
| 4.3 | Tratamento do Sinal | p. 45 |
| 4.4 | Extração de Características | p. 48 |
| 4.5 | Reconhecimento de Padrões | p. 49 |
| 5 | Trabalho Desenvolvido | p. 52 |
| 5.1 | Aquisição dos Sinais | p. 53 |
| 5.2 | Re-amostragem do Sinal | p. 53 |
| 5.3 | Classificador Netlab MLP | p. 57 |
| 5.4 | Classificador Netlab GLM | p. 58 |
| 5.5 | Classificador LDA | p. 58 |

| | | |
|----------|---------------------------------------|-------|
| 5.6 | Conjunto de Características | p. 59 |
| 5.6.1 | Cardinalidade | p. 60 |
| 5.6.2 | Cruzamento de Zero | p. 61 |
| 5.6.3 | Comprimento de Onda | p. 61 |
| 5.6.4 | Valor Absoluto Médio | p. 61 |
| 5.7 | Planejamento do Experimento | p. 61 |
| 5.8 | Tratamento do Sinal | p. 63 |
| 5.9 | Ambiente de Teste | p. 64 |
| 5.10 | Análise Estatística | p. 64 |
| 6 | Resultados | p. 66 |
| 6.1 | Netlab MLP | p. 66 |
| 6.2 | Netlab GLM - scg | p. 71 |
| 6.3 | Netlab GLM - irls | p. 74 |
| 6.4 | LDA | p. 77 |
| 7 | Análise Comparativa | p. 78 |
| 7.1 | Netlab MLP | p. 78 |
| 7.2 | Netlab GLM - scg | p. 79 |
| 7.3 | Netlab GLM - irls | p. 79 |
| 7.4 | LDA | p. 80 |
| 7.5 | Estudo sobre a População | p. 81 |
| 8 | Conclusão | p. 83 |

9 Trabalhos Futuros

p. 85

Referências

p. 87

Lista de Figuras

| | | |
|----|--|-------|
| 1 | Mudança de potencial da membrana celular (SANTOS, 2015). | p. 24 |
| 2 | Junção da terminação do neurônio com a placa motora (BORGES, 2014). | p. 26 |
| 3 | Ligação do neurônio com a fibra muscular (MÚSCULOS..., 2017). | p. 27 |
| 4 | Somatório do sinal gerado pela ativação de diferentes unidades motoras para geração do sinal mioelétrico completo de um movimento qualquer (HOWARD, 2016). | p. 28 |
| 5 | Dez sinais mioelétricos sobrepostos. Cada cor indica um tipo de movimento, imagem obtida com o Matlab. | p. 29 |
| 6 | Esquema para reconhecimento de padrões. | p. 31 |
| 7 | Fluxograma para classificação supervisionada e não supervisionada. | p. 34 |
| 8 | Diferentes populações sendo agrupadas em classes diferentes. | p. 36 |
| 9 | Modelo conceitual de uma rede MLP (MIX, 2010). | p. 38 |
| 10 | Solução insuficiente, resultado de uma rede com complexidade muito baixa (PAPAGELIS; KIM, 2017). | p. 41 |
| 11 | Solução apresentada por uma rede muito complexa(1) e solução de uma rede ideal(2) (PAPAGELIS; KIM, 2017). | p. 41 |
| 12 | Diagrama de blocos que ilustra o funcionamento geral da plataforma BioPatRec (ORTIZ-CATALAN, 2017). | p. 44 |
| 13 | Ajuste dos parâmetros antes da gravação (ORTIZ-CATALAN, 2017). | p. 45 |

| | | |
|----|---|-------|
| 14 | Sinal gravado resultante (ORTIZ-CATALAN, 2017). | p. 46 |
| 15 | Interface para o tratamento do sinal. É possível fazer a re-amostragem do sinal, aplicação de filtros e definição do tamanho das janelas de características (ORTIZ-CATALAN, 2017). | p. 47 |
| 16 | Duas configurações possíveis para as janelas de características: sobrepostas ou janelas sequenciais (ORTIZ-CATALAN, 2017). | p. 48 |
| 17 | Interface gráfica para reconhecimento de padrões (ORTIZ-CATALAN, 2017). | p. 50 |
| 18 | Transformada de Fourier do sinal 1. A maior frequência fica em torno de 450 Hz, o lado direito da imagem é um espelho do resultado, imagem obtida com auxílio do Matlab. | p. 55 |
| 19 | Estrutura de dados do sinal original na plataforma BioPatRec, obtida com o Matlab. | p. 56 |
| 20 | Estrutura de dados do sinal re-amostrado, obtida com o Matlab. | p. 57 |
| 21 | Netlab MLP alimentado pelo sinal original e re-amostrado. Variou-se o número de neurônios e iterações da rede para se obter uma relação de desempenho do algoritmo em diferentes casos. | p. 62 |
| 22 | Os dois algoritmos otimizados de treino do Netlab GLM são avaliados com relação ao número de iterações e conjuntos de características que alimentam os mesmos. | p. 63 |
| 23 | Modelo linear clássico alimentado por diferentes grupos de características. | p. 63 |
| 24 | Relação de desempenho quando a medida é a precisão na predição dos movimentos. A qualidade dos resultados aumenta à medida que a complexidade da rede aumenta. | p. 68 |

| | | |
|----|---|-------|
| 25 | O tempo de treinamento diminui quando a complexidade do sistema é menor, em contrapartida os resultados seguem a tendência inversa. | p. 69 |
| 26 | Resultado do teste t pareado aplicado as duas amostras (sinal original e re-amostrado) de resultados da rede Netlab MLP, com relação a acurácia. | p. 70 |
| 27 | Resultado do teste t pareado aplicado as duas amostras (sinal original e re-amostrado) da rede Netlab MLP, com relação ao tempo. | p. 71 |
| 28 | Variação da precisão para diferentes configurações. A diferença entre os resultados da rede quando alimentada por 5 conjuntos de características é inferior a 2%, em comparação ao algoritmo alimentado por todos os conjuntos. | p. 73 |
| 29 | Relação de tempo de treino para os diversos arranjos da rede. . . | p. 74 |
| 30 | A precisão não sofre variação nos resultados quando o número de iterações varia. O único fator relevante para este método de treinamento otimizado é o conjunto de características que alimentam o algoritmo. | p. 76 |
| 31 | Tal como com a precisão, o tempo não mostrou variações significativas em relação ao número de iterações. Isso sugere que a rede funciona bem com um número reduzido de ciclos. | p. 76 |
| 32 | Acurácia média por indivíduo. Rede GLM-scg alimentada por todas as características com 200 iterações. | p. 81 |
| 33 | Acurácia média por indivíduo. Rede MLP com 32 neurônios realizando 200 iterações. | p. 82 |

Lista de Tabelas

| | | |
|---|---|-------|
| 1 | Netlab MLP - Sinal Original | p. 67 |
| 2 | Netlab MLP - Sinal Re-amostrado | p. 68 |
| 3 | Netlab GLM - SCG | p. 72 |
| 4 | Netlab GLM - IRLS | p. 75 |
| 5 | LDA | p. 77 |

Glossário

| | |
|---------|--|
| LDA | <i>Análise Discriminante Linear</i> |
| MLP | <i>Perceptron Multi Camadas</i> |
| GLM | <i>Modelo Linear Geral</i> |
| SME | <i>Sinal Mioelétrico</i> |
| MUAP | <i>Potencial de Ação de uma Unidade Motora</i> |
| GUI | <i>Interface Gráfica do Usuário</i> |
| SDF | <i>Diferencial Simples</i> |
| DDF | <i>Diferencial Dupla</i> |
| KNN | <i>Kernel Nearest Neighbors</i> |
| RFN | <i>Regulatory Feedback Networks</i> |
| SOM | <i>Mapas Auto Organizáveis</i> |
| SSOM | <i>Mapas Auto Organizáveis Supervisionado</i> |
| Ag/AgCl | <i>Eletrodo de cloreto de prata</i> |
| DC | <i>Componente Contínua</i> |
| irls | <i>Mínimos Quadrados Iterativamente Ponderados</i> |
| scg | <i>Gradiente Conjugado Escalonado</i> |
| tcard | <i>Cardinalidade</i> |
| twl | <i>Comprimento de Onda</i> |
| tmabs | <i>Valor Absoluto Médio</i> |
| tzc | <i>Cruzamento de Zeros</i> |
| tslpch2 | <i>Mudança de Inclinação</i> |

1 Introdução

Portadores de deficiência ainda enfrentam diversos problemas dentro da sociedade. Questões como inclusão social, respeito à legislação vigente e a utilização de tecnologia para mitigar tais dificuldades ainda são incipientes (KUIKEN, 2016). Atividades cotidianas, como tomar banho ou abrir uma porta, acabam se tornando grandes desafios para estes indivíduos. Muitos trabalhos já foram propostos a fim de reabilitar essas pessoas e segundo Farina et al. (2014) e Jiang et al. (2012a) existe uma disparidade entre as soluções comerciais e acadêmicas, o que acaba inviabilizando a criação de um sistema robusto capaz de mitigar totalmente esse problema. Nos últimos 60 anos os pesquisadores têm obtido sucesso em suas abordagens, porém, nenhuma delas foi totalmente implementada em um sistema comercial (JIANG et al., 2012a) e a maioria das próteses são apenas cosméticas (DAVIDSON, 2002). Dentre todas as soluções apresentadas para se criar um sistema de reabilitação funcional, o uso do sinal mioelétrico (SME) tem sido utilizado amplamente e se mostrado eficiente com relação a acurácia dos resultados e computacionalmente viável (ENGLEHART; HUDGINS, 2013; FUGNER et al., 2012).

O sinal mioelétrico (SME), proveniente da contração muscular, carrega informações com as quais é possível distinguir os diferentes movimentos de um membro amputado e para isso utiliza-se o sinal elétrico que é captado na superfície da pele ou nervos mais internos do membro (FOUGNER et al., 2012). Com a potencial carga de informação no sinal é possível criar dispositivos que identifiquem os movimentos e possam reproduzi-los em uma prótese (ENGLEHART; HUDGINS, 2013). Além do mais, o uso do sinal mioelétrico se torna intuitivo para a pessoa que teve seu mem-

bro amputado ou nasceu com algum tipo de deficiência, visto que é proveniente do comando cerebral que é passado ao músculo através dos axônios dos neurônios, assim, esse sinal é estritamente relacionado ao sinal cerebral que gera o comando para determinado movimento, tornando a operação do sistema mais próxima do natural.

Nos primeiros estudos sobre o sinal mioelétrico, o mesmo foi considerado estocástico, ou seja, um evento aleatório o qual é impossível prever sua natureza. Porém, trabalhos mais recentes como (HUDGINS; PARKER; SCOTT, 1993) e (FARRELL; WEIR, 2007a) mostraram que é possível reconhecer certas características do SME nos 200 milissegundos iniciais de uma contração muscular, assim sendo, esses padrões podem ser utilizados para reconhecer cada tipo de movimento que o indivíduo deseja realizar, tornando a reprodução dos mesmos viável.

Os classificadores que fazem o reconhecimento do padrão de movimento não são alimentados diretamente pela própria onda. Antes de realizar o processo de classificação o sinal deve ser filtrado a fim de se remover alguns artefatos indesejados, como ruído, componentes harmônicas ou alguma componente contínua oriunda do aparelho que faz a amostragem. Após o tratamento adequado da amostra coletada, é necessário realizar a extração de características, ou seja, a máquina não é abastecida diretamente com o sinal tratado e sim com vetores de características extraídos da onda.

Diversos conjuntos de características para reconhecimento de padrões no SME foram desenvolvidos nos últimos anos. Valor Absoluto Médio (*Mean Absolute Value*), Valor Absoluto Médio de Declive (*Mean Absolute Value Slope*), Cruzamentos de Zeros (*Zero Crossings*), Comprimento da Forma de Onda (*Waveform Length*) foram apresentados em 1993 por Hudgins, Parker e N (1993) e de lá para cá muitas outras técnicas e abordagens foram propostas (ORTIZ-CATALAN; BRANEMARK; HAKANSSON, 2013). Com tais técnicas, é possível criar sistemas capazes de reconhecer o padrão de cada movimento e sua relação com o sinal enviado ao músculo. A partir das peculiaridades do sinal, alguns algoritmos como Discriminantes Lineares (LDA), Perceptron Multicamadas (MLP), Mapas Auto Organizáveis e outros,

já estão sendo usados por alguns autores a fim de se desenvolver algum tipo de sistema de reabilitação.

Um dos desafios da área é conseguir a maior qualidade possível no reconhecimento do movimento. Por se tratar de um sistema crítico, é desejável que não haja interpretações erradas da rede e o tempo de resposta seja próximo do comportamento humano. Quando fala-se em qualidade no reconhecimento dos padrões, deve-se levar em consideração diversos fatores, um deles é a acurácia, ou seja, qual o grau de distinção de um dado movimento com relação a outro. Outro fator relevante é o tempo em que o sistema proposto é capaz de realizar sua tarefa.

Uma das exigências de um sistema de reabilitação é alta confiabilidade, ou seja, o sistema não deve fazer nenhuma interpretação errada dos movimentos, ou isso geraria alguns problemas no cotidiano da pessoa que utiliza a prótese. Mesmo com uma taxa de acerto de 99% o indivíduo estaria sujeito a quebrar um copo ou derrubar alguma coisa, nesse sentido a alta acurácia na predição dos movimentos é a métrica mais desejada para esse tipo de problema. Outro requisito é o tempo que o algoritmo leva para distinguir um movimento do outro, em termos práticos ele deve ser capaz de fazê-lo em tempo real. O uso da prótese deve ser intuitivo e parecido com o comportamento humano e segundo Farina et al. (2014) e Davidson (2002) muitas pessoas abandonam a solução devido a dificuldade de utilização e tempo de resposta lento.

O tempo de treino da rede também é outro fator limitante (FARRELL; WEIR, 2007b), uma solução que funcione em tempo real deve realizar ao longo do dia algumas operações de treino, visto que, o sistema sempre vai estar em constante variação. Alterações como fadiga, esforço do usuário, umidade do ar e temperatura ambiente podem mudar algumas características do sinal (FOUGNER et al., 2011), sendo assim, é necessário refazer o treinamento dos classificadores para que o sistema sempre funcione com uma configuração ótima, independente da forma de utilização ou de fatores ambientais que possam interferir na prótese (FARINA et al., 2014).

1.1 Análise Discriminante Linear - LDA

Análise Discriminante Linear é um método usado para reconhecimento de padrões, aprendizado de máquina, análises estatísticas (LINEAR..., 2018) e é uma generalização do modelo geral proposto por Fisher (1936) . Utiliza-se em sua arquitetura um método linear para separar duas ou mais classes de objetos ou eventos (sinais). Esse classificador é usado como referência em muitos trabalhos semelhantes e é o que apresenta o melhor tempo de treino, porém não apresenta a melhor acurácia na predição dos movimentos.

1.2 Netlab MLP

Netlab MLP é um algoritmo de rede neural artificial de propósito geral que utiliza Perceptron Multi Camadas em sua arquitetura (ORTIZ-CATALAN et al., 2016). Diferente de outras redes MLP que foram avaliadas por outros autores, a rede Netlab possui métodos otimizados de treino e tem apresentado bons resultados com relação ao tempo e a qualidade no reconhecimento de padrões em relação à arquiteturas semelhantes (ORTIZ-CATALAN et al., 2016). A abordagem foi testada no que concerne ao número de neurônios na camada escondida, número máximo de iterações da rede e com relação ao sinal que chega ao classificador.

Trabalhos como (FARINA et al., 2014) mostraram que dispositivos embarcados devem atender a requisitos de baixa complexidade de *hardware*, questões como consumo de energia, memória e manipulação de grandes conjuntos de dados podem ser fatores limitantes para a construção de uma prótese. Como toda informação para classificação dos movimentos é oriunda do SME pretende-se verificar se é possível trabalhar com uma quantidade menor de dados, porém, com a mesma representação do sinal original. A ferramenta Matlab[®] foi utilizada para realizar a re-amostragem do sinal original e gerar um novo sinal com metade dos pontos, representando a mesma informação do conjunto anterior. Para isso, utilizou-se a

condição do Teorema da Amostragem de Nyquist (NYQUIST, 1928) para verificar a consistência dos dados. Dessa maneira, o classificador Netlab MLP foi avaliado com relação a sua capacidade de trabalhar com um conjunto de dados generalizado.

1.3 Netlab GLM

O último algoritmo avaliado foi Netlab GLM, que assim como o LDA é um método linear, que possui algoritmos otimizados de treino (ORTIZ-CATALAN et al., 2016). O método GLM foi examinado com relação aos conjuntos de características que alimentam a rede e com relação ao número de iterações máximas que o classificador pode realizar para predição dos movimentos. Os dois métodos otimizados disponíveis na ferramenta foram testados separadamente. Para o desenvolvimento desse estudo será utilizada uma plataforma de pesquisa em código aberto desenvolvida em Matlab[®] (*MathWorks*) chamada BioPatRec (ORTIZ-CATALAN; BRANEMARK; HAKANSSON, 2013), a mesma disponibiliza módulos voltados para o controle de membros artificiais, tratamento do sinal elétrico e algoritmos de reconhecimento de padrões.

1.4 Objetivo

O objetivo dessa dissertação é fazer um estudo de performance de três métodos para reconhecimento de padrão do sinal mioelétrico, Netlab GLM, Netlab MLP e LDA. O trabalho visa fornecer uma tabela de operação para cada um dos classificadores, onde a acurácia na predição dos movimentos e o tempo de treino são as medidas desejadas. Os classificadores foram testados em diferentes configurações e de acordo com a arquitetura de cada um deles. A motivação do estudo é encontrar a melhor relação custo benefício para cada um dos algoritmos e verificar qual das abordagens possui características mais viáveis para futuramente embarca-la em um prótese.

Para o algoritmo Netlab MLP o objetivo é verificar qual a melhor faixa de operação, variando-se:

- Número de neurônios na camada escondida;
- Número máximo de iterações;
- Sinal que alimenta o classificador.

Para o método GLM o propósito dos testes é verificar qual dos métodos otimizados de treino (scg ou irls) apresetam melhores resultados para essa classe de problema, para isso verificou-se o seu desempenho quando as seguintes variáveis foram avaliadas:

- Número máximo de iterações;
- Conjuntos de características que chegam até a rede.

1.5 Estrutura da Dissertação

O capítulo 2 (O Sinal Mioelétrico) aborda as questões relacionadas a fisiologia do sinal mioelétrico, seu funcionamento biológico, sua utilização por outras cadeiras do conhecimento através da miografia e apresenta um breve histórico científico da área. O capítulo 3 (Classificadores) refere-se a arquitetura das ferramentas de classificação, os diferentes tipos de classificação, as diferenças básicas entre algumas abordagens e apresenta um histórico sobre o desenvolvimento de alguns algoritmos de reconhecimento de padrões. O capítulo 4 (BioPatRec) apresenta a plataforma utilizada no trabalho para avaliação dos classificadores, explica a motivação do seu desenvolvimento, sua arquitetura básica de funcionamento e apresenta os módulos disponíveis para manipulação do sinal mioelétrico. O capítulo 5 (Trabalho Desenvolvido) descreve os procedimentos necessários para realização dos experimentos e apresenta o protocolo de teste desenvolvido. O capítulo 6 (Resultados) traz os

resultados obtidos por cada classificador nas diferentes configurações propostas no protocolo de teste. O capítulo 7 (Análise Comparativa) faz uma discussão geral dos resultados. O capítulo 8 trata-se da Conclusão. O capítulo 9 apresenta uma perspectiva futura para continuidade desse trabalhos

2 O Sinal Mioelétrico

O sinal mioelétrico é oriundo do potencial de ação que percorre a fibra muscular levando-a à contração (ORTOLAN, 2002). O tecido muscular esquelético constitui a musculatura do corpo e é popularmente chamado de carne, esse tecido recobre o esqueleto e está preso aos ossos. O músculo é composto por unidades motoras, que por sua vez são formadas por fibras musculares que possuem ramos terminais ligadas à medula espinhal (MERLETTI; KNAFLITZ, 1992). O sistema nervoso central e periférico controlam a atividade muscular modulando o número de motoneurônios e a taxa com que são recrutados para tal atividade. Esses fatores são determinados pela atividade sináptica que ocorre entre as células dos motoneurônios e o ramo terminal dessas células que inervam a fibra muscular. Esses motoneurônios são capazes de disparar uma reação que provoca a despolarização do meio e se propaga em duas direções opostas à fibra muscular (MERLETTI; KNAFLITZ, 1992), essas atividades geram dois potenciais de ação.

A eletromiografia consiste na técnica de monitoramento do SME ao longo do tempo (tensão em função do tempo) e é utilizada entre outras coisas como método de avaliação e diagnóstico de problemas nos nervos e nos músculos, que permite o estudo relativo à fadiga muscular e níveis de ativação muscular. Tem sido usada para diagnosticar certos sintomas, como dores musculares, fraqueza, câimbras e movimentos involuntários. O fenômeno foi descoberto por Luigi Galvani em 1780 (PICCOLINO, 1998) durante uma aula de fisiologia animal. Ele percebeu que os músculos são estimulados por sinais elétricos quando tocou uma rã morta com dois metais diferentes, e a mesma sofreu violentas contrações. Na época da

descoberta ele deduziu que a rã possui uma carga elétrica e denominou essa força de eletricidade animal. Atualmente, a eletromiografia é usada por diversas áreas do conhecimento, notoriamente na medicina, odontologia, fonoaudiologia, fisioterapia e educação física.

2.1 Potencial de Ação

Os potenciais de ação neurais são reações eletroquímicas responsáveis pela condução dos sinais nervosos nos neurônios e podem ser descritos como variações muito rápidas dos potenciais externo e interno da membrana da célula nervosa (ORTOLAN, 2002) e (FARINA et al., 2010). As fases do potencial de ação são descritas a seguir:

- **Despolarização:** Nessa fase, ocorre um aumento na permeabilidade aos íons de sódio na membrana celular. Isso ocasiona um grande fluxo de íons de sódio (Na^+) de fora para dentro da célula através de sua membrana, por um processo de difusão simples. Como resultado do fenômeno citado acima, o líquido intracelular passa a apresentar uma grande quantidade de íons de carga positiva (cátions) e a membrana celular apresenta agora um potencial inverso daquele encontrado nas condições de repouso da célula. O potencial de membrana nesse período passa a ser, portanto, positivo (algo em torno de +30 até +50 milivolts).
- **Repolarização:** Durante um pequeno período, a permeabilidade na membrana celular aos íons de sódio retorna ao normal e ocorre agora um aumento na permeabilidade aos íons de potássio (K^+). Isso provoca um grande fluxo de íons de potássio de dentro para fora da célula. Enquanto isso, os íons sódio (cátions) que estavam em grande quantidade no interior da célula vão sendo transportados ativamente para o exterior da mesma, pela bomba de sódio-potássio. Tudo isso faz com que o potencial na membrana celular volte

a ser negativo. O potencial de membrana, nesse período, passa a ser algo em torno de -75 milivolts.

- **Repouso:** É a última fase do processo. É o retorno às condições normais de repouso encontradas na membrana celular antes da mesma ser excitada e despolarizada. Nessa fase, a permeabilidade aos íons de potássio retorna ao normal. O potencial da membrana celular retorna ao seu valor de repouso, cerca de -70 milivolts.

A figura 1 ilustra a mudança de potencial da membrana celular durante as três fases, para que ocorra a despolarização deve haver algum estímulo (químico, elétrico, térmico ou mecânico).




Figura 1: Mudança de potencial da membrana celular (SANTOS, 2015).

2.2 Junção Neuromuscular

A junção neuromuscular é a ligação entre a parte final de um axônio de um neurônio motor com uma placa motora, que é a região da membrana plasmática de uma fibra muscular onde se dá o encontro entre o nervo e o músculo, permitindo desencadear a contração muscular. Na junção neuromuscular, o neurotransmissor utilizado é a acetilcolina. A fibra nervosa ramifica-se no final para formar a placa terminal, que se invagina para dentro da fibra muscular, mas repousa inteiramente na parte externa da membrana (ORTOLAN, 2002). A placa motora é onde o estímulo elétrico tem de ser transformado em movimento, através de alguns mediadores químicos que permitem essa transformação, dentre eles a acetilcolina.

Quando um potencial de ação chega ao terminal do axônio, ocorre a liberação de acetilcolina e com isso os receptores da mesma tornam a membrana muscular mais permeável a íons de Sódio (Na^+). A abundância destes íons no músculo cria o potencial de ação muscular, que atravessa a membrana da fibra muscular da mesma forma como nas membranas neurais, porém nas duas direções do músculo (FARINA et al., 2010). Logo em seguida ocorre a despolarização da membrana e a acetilcolina é transformada em ácido acético e colina, esse processo dura 200 milissegundos e é necessário para que a placa motora fique pronta para um novo estímulo. A figura 2 é uma imagem de microscópio que mostra a junção entre os axônios e a placa motora.

2.3 Unidade Motora

A unidade motora é formada por um conjunto de fibras musculares que são gerenciadas por um único neurônio motor (FARINA et al., 2010). Uma fibra nervosa pode enervar desde uma até centenas de fibras musculares, este número é conhecido como taxa de enervação. Visto que, existem muito mais fibras musculares do que neurônios motores, os axônios - parte do neurônio responsável pela condução dos impulsos elétricos - ramificam-se de forma a comunicarem com as diferentes

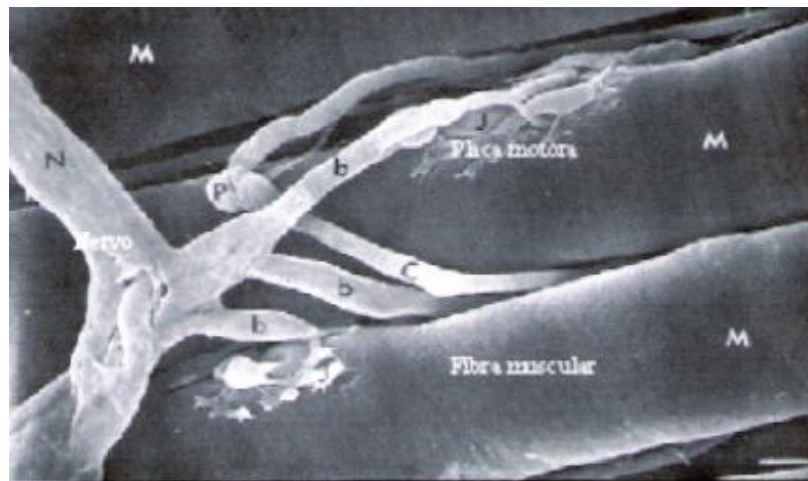


Figura 2: Junção da terminação do neurônio com a placa motora (BORGES, 2014).

fibras musculares.

Tanto as unidades motoras como os neurônios motores que as inervam podem ter diferentes tamanhos. Neurônios motores pequenos inervam relativamente poucas fibras musculares, formando unidades motoras capazes de gerar uma força menor. Já neurônios motores grandes inervam muitas fibras musculares, formando unidades motoras maiores e mais fortes. O controle da força é realizado pelo número de unidades motoras recrutadas em uma dada contração. A força que um músculo executa também é regulada pela frequência de estimulação de uma unidade motora. A partir de uma certa frequência, os estímulos irão se sobrepor resultando numa contração suave e gradual do músculo. Este fenômeno é conhecido como tetanização. As frequências de estimulação, para que a tetanização ocorra, vão de 20 Hz para as fibras musculares lentas a 100 Hz para as fibras rápidas (ORTOLAN, 2002). A figura 3 ilustra como o neurônio motor se liga as fibras musculares.

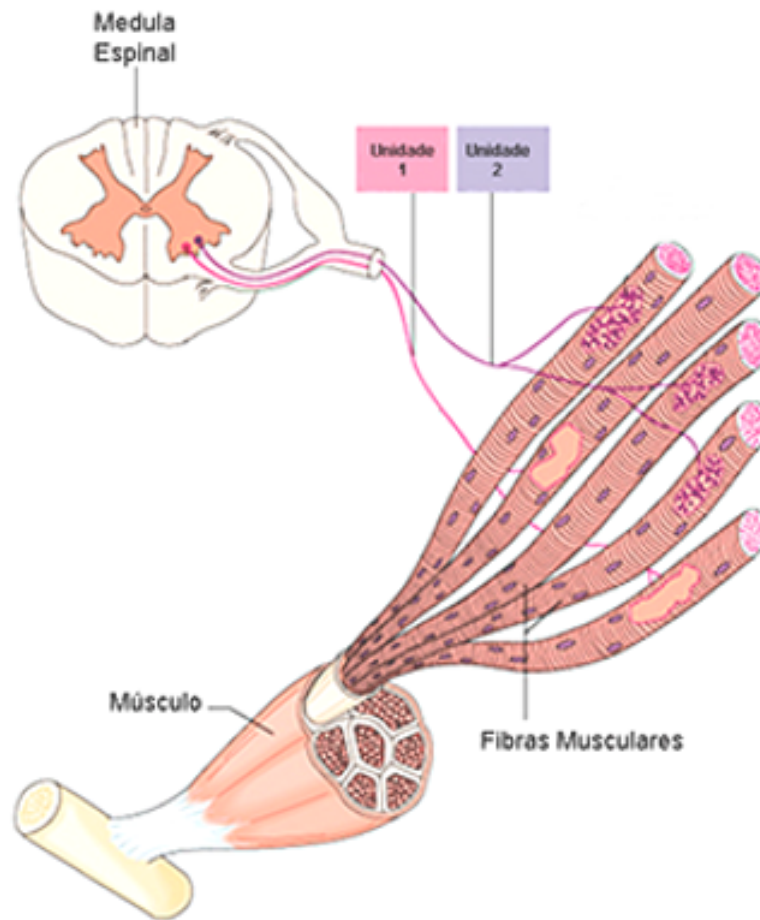


Figura 3: Ligação do neurônio com a fibra muscular (MÚSCULOS..., 2017).

2.4 Características do Sinal Mioelétrico

Quando um neurônio motor envia um potencial de ação, as fibras musculares da sua unidade motora são estimuladas (FARINA et al., 2010). Todavia, as fibras não são estimuladas simultaneamente, ocorrendo pequenos atrasos entre as contrações. O atraso ocorre devido aos diferentes tempos de propagação das várias ramificações dos axônios no neurônio motor e por causa da natureza aleatória das descargas de acetilcolina nas junções neuromusculares. O resultado da soma algébrica dos potenciais de ação nas n fibras de uma unidade motora é chamado de potencial de ação da unidade motora, cuja sigla em inglês é MUAP (*Motor Unit*

Action Potential). Como a MUAP tem um período pequeno (entre 2 e 10 ms), as unidades devem ser ativadas de maneira repetitiva para que se possa suportar uma contração por períodos maiores. Esse seguimento de potenciais é chamado trem de potenciais de ação da unidade motora. Os MUAPs, ao percorrer as fibras musculares, geram um campo eletromagnético próximo às fibras.

Um eletrodo, localizado dentro deste campo, é capaz de detectar o potencial elétrico referente a uma contração muscular, que é chamado de Sinal Mioelétrico (SME) (ORTOLAN, 2002). A soma de vários potenciais de ação gera o sinal mioelétrico (HENNEMAN, 1985; LUCA et al., 1982), que é diferente para cada conjunto somado e representa um só tipo de movimento basicamente, ou seja, a ativação de diferentes unidades motoras geram tipos diferentes de SME, a figura 4 ilustra essa situação, onde o somatório da contribuição individual de cada unidade, resulta no sinal mioelétrico completo para um dado movimento.




Figura 4: Somatório do sinal gerado pela ativação de diferentes unidades motoras para geração do sinal mioelétrico completo de um movimento qualquer (HOWARD, 2016).

A figura 5 mostra 10 sinais sobrepostos que representam 10 movimentos diferentes, com intervalo de 3 segundos entre cada contração, é possível uma distinção visual entre os sinais através do mapa de cores, onde cada sinal só pode ser representado por uma cor.




Figura 5: Dez sinais mioelétricos sobrepostos. Cada cor indica um tipo de movimento, imagem obtida com o Matlab.

3 Classificadores

3.1 Reconhecimento de Padrões

O reconhecimento de padrões é um ramo de aprendizado de máquina onde o objetivo é a classificação de objetos em diferentes classes, R.C. e M.G (1978) definem reconhecimento de padrões como a classificação de dados de entrada através da extração de importantes características a partir de certos conjuntos de dados. Estes objetos podem ser os mais variados, como sinais (voz, rádio ou miografia), imagens ou qualquer grupo que se queira separar em diferentes classes (tipos de movimentos de um membro). Os sistemas de reconhecimento são, em muitos casos, treinados a partir de dados rotulados de treinamento (aprendizagem supervisionada), mas quando não há dados rotulados disponíveis, outros algoritmos podem ser usados para descobrir padrões desconhecidos anteriormente (aprendizado sem supervisão).

O reconhecimento de padrões visa a atribuição de um rótulo a um dado valor de entrada. Com essa mesma finalidade a análise discriminante foi concebida em 1936 para problemas estatísticos e se difundiu por outras áreas do conhecimento (VARELLA, 2017). A classificação é um exemplo de reconhecimento, onde, para cada valor de entrada, atribui-se uma classe correspondente, por exemplo, imagine que entrada do sistema seja sinais da voz humana e quer-se alocar cada sinal em determinado conjuntos de classes (barítono, soprano e contralto), cada sinal deve possuir características que os colocam em um dos grupos de classes.

Um sistema de reconhecimento de padrões é composto por um sensor (elétrodo,

termômetro, indicador de umidade) que faz a captação dos dados a serem descritos, uma unidade de tratamento do dado captado e um algoritmo de classificação. Após a coleta de dados existe um mecanismo que faz a extração de determinadas características, que são relevantes para o problema em questão e servem como dados para os classificadores poderem tomar algum tipo de decisão. E finalmente há um esquema para classificar esse dado, o resultado é categorizado conforme cada padrão de interesse.

Os classificadores não devem ser muito generalizados e nem muito específicos, pois no primeiro caso sua classificação seria vaga e no segundo excluiria algum dado relevante. As definições básicas de reconhecimento de padrões são:

- **Padrão:** Entidade, evento ou objeto, com uma dada definição para o seu agrupamento;
- **Classe:** Agrupamento de padrões os quais possuem atributos semelhantes;
- **Atributo:** Dado significativo obtido através da extração de características;
- **Classificação:** Atribuição de classes para as entradas através de consideração de seus atributos.

A figura 6 ilustra os passos necessários para reconhecimento de padrões, em um esquema hipotético.




Figura 6: Esquema para reconhecimento de padrões.

Basicamente o reconhecimento de padrão pode ser usado para três tipos de problemas: classificação de várias classes, duas classes ou apenas uma classe (caso

onde quer-se detectar um tipo de anomalia). Para cada um dos casos existe um tipo de algoritmo que se adapta melhor ao problema e não há uma regra geral. Se o interesse é a alta acurácia pode-se utilizar uma rede neural ou um perceptron multi camadas, no caso onde há apenas duas classes de interesse um modelo linear pode funcionar bem.

3.2 Classificação Supervisionada

Na classificação supervisionada, o desenvolvedor ou o analista supervisiona o processo de classificação dos objetos. Cada valor dentro das características deve ser atribuído a uma classe de interesse, isso é feito selecionando valores previamente conhecidos (CARRIZOSA; M.BARRAGÃ;N; MORALES, 2011). Cada exemplo é composto por um par de interesse, contendo o vetor de entrada e um vetor com a saída desejada. O algoritmo deve ser capaz de analisar os dados de treino e produzir uma função de saída capacitada a mapear novos itens.

A classificação supervisionada pode ser muito mais precisa do que a classificação não supervisionada, mas depende fortemente do treinamento. Se duas ou mais classes são muito semelhantes entre si, as classificações erradas tenderão a ser altas. O reconhecimento supervisionado requer atenção a escolha dos dados de treinamento. Se os dados de treinamento forem ruins ou não representativos, os resultados da classificação também serão ruins. Algumas abordagens que utilizam classificação supervisionadas são:

- Redes Neurais Artificiais;
- Algoritmos de retropropagação;
- Estimador Kernel;
- *Support Vector Machines*;
- Árvores de Decisão por Aprendizagem.

3.3 Classificação Não Supervisionada

A classificação não supervisionada é essencialmente automatizada pelo computador. O usuário especifica o número de classes e as mesmas são criadas exclusivamente com base nas informações numéricas dos dados (valor eficaz da onda, frequência máxima contida no sinal, etc). Os algoritmos de agrupamento são usados para determinar o agrupamento natural ou estatístico dos dados. Os objetos são agrupados em função da sua semelhança espectral. O computador usa espaço de características para analisar e agrupar os dados em classes. Assim, as técnicas de classificação não supervisionadas dividem os conjuntos de dados em *clusters*, garantindo que a variabilidade *intercluster* seja maximizada e minimizando a variabilidade intra classe (ISHOLA; NAWAWI; ABDULLAH, 2014).

Embora o processo seja basicamente automatizado, o usuário tem controle sobre certas entradas. Isso inclui o número de classes, as iterações máximas (que é quantas vezes o algoritmo de classificação é executado) e o limite de alteração, que especifica quando terminar o procedimento de classificação. Após a classificação dos dados, o desenvolvedor deve interpretar, rotular e codificar as classes. A classificação não supervisionada é bastante rápida e fácil de executar. Não é necessário conhecimento prévio da área requerida, mas deve-se ser capaz de identificar e rotular os objetos e classes de interesse.

Abaixo alguns algoritmos que utilizam classificação não supervisionada em sua arquitetura:

- *K-means*;
- *Mixture Models*;
- *Hierarchical Clustering*.

O diagrama da figura 7 mostra o fluxograma para os métodos de classificação. Diferente da abordagem supervisionada onde a máquina é alimentada com vetores

de treino, a abordagem não supervisionada trabalha com agrupamento de dados (Clusterização).

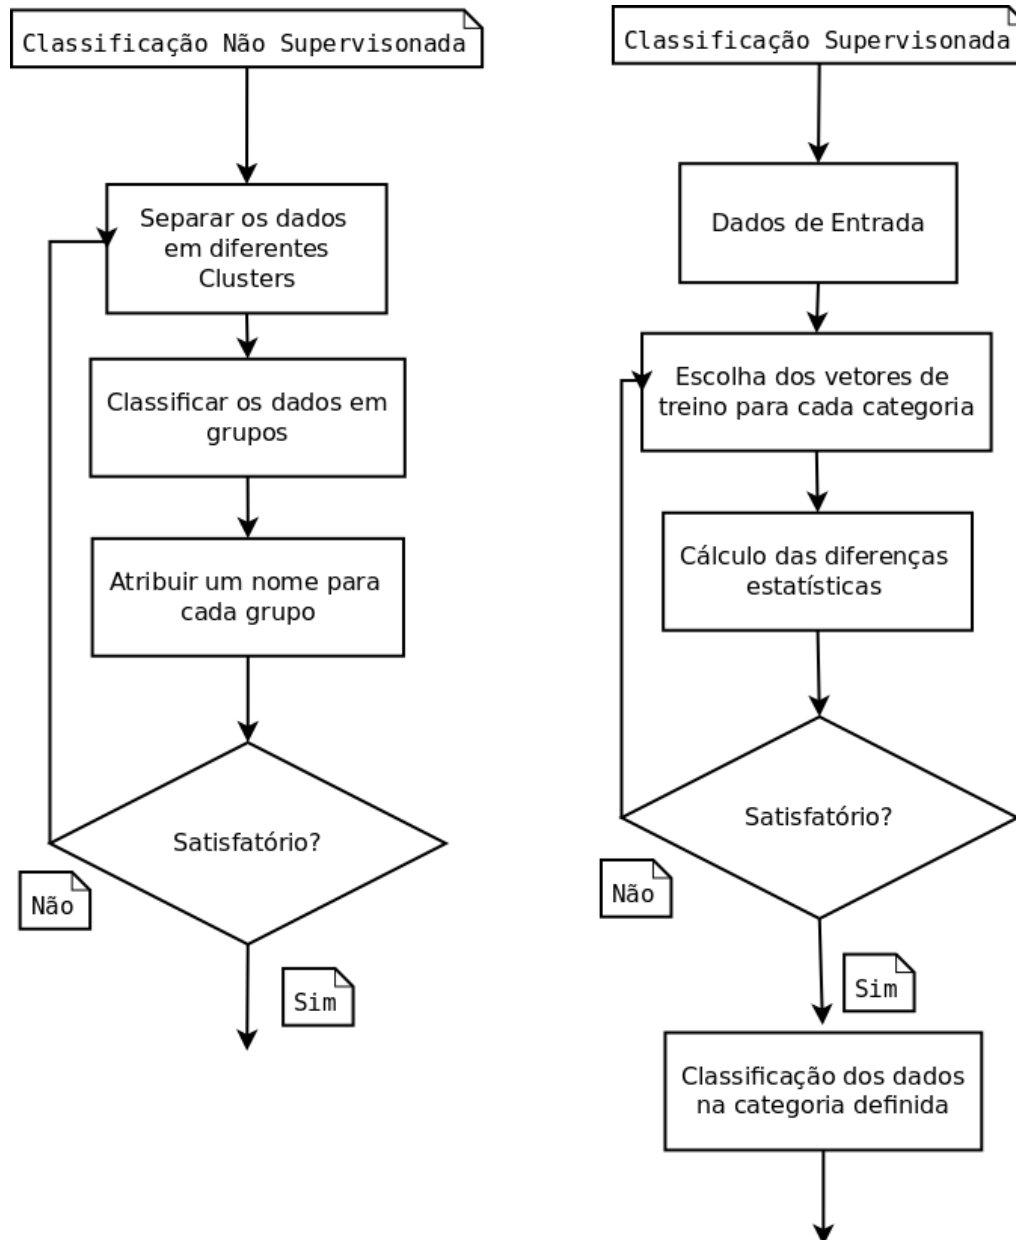


Figura 7: Fluxograma para classificação supervisionada e não supervisionada.

3.4 Análise Discriminante Linear - LDA

A análise discriminante é uma técnica da estatística utilizada para discriminar e classificar objetos (VARELLA, 2017). É comumente usada como técnica para redução de dimensionalidade para soluções que demandam classificação de padrões e de aprendizagem de máquinas. O objetivo é projetar um conjunto de dados em um espaço de menor dimensão com boa margem de separabilidade entre as classes, para evitar a superposição e também reduzir custos computacionais. Ronald A. Fisher formulou a LDA em 1936 (*The Use of Multiple Measurements in Taxonomic Problems*) (VARELLA, 2017). Originalmente a LDA foi concebida para resolver problemas envolvendo apenas duas classes e posteriormente houve uma generalização do algoritmo para múltiplas classes.

O objetivo do algoritmo é desenvolver funções discriminantes a partir da combinação linear de variáveis independentes, que discriminarão entre as categorias das variáveis dependentes de maneira perfeita. Permite ao pesquisador verificar se existem diferenças significativas entre os grupos, em termos das variáveis preditoras. Ela também avalia a precisão da classificação. A LDA projeta um espaço de características (um conjunto de dados de amostra *n-dimensionalis*) em um sub espaço k , onde $k \leq n-1$.

3.4.1 Discriminação e Classificação

O objetivo é obter uma combinação linear do conjunto de características observadas que apresente uma relação de discriminação entre os objetos que se quer agrupar em classes. A função tem a propriedade de minimizar as probabilidades de má classificação, quando as populações são normalmente distribuídas com média e variância conhecidas. Como a média e a variância das populações não são conhecidas inicialmente, esses parâmetros devem ser estimados (VARELLA, 2017). Essa função deve ser capaz de criar regiões de separação entre as classes e esta função é obtida através de amostras de treino. A figura 8 mostra três regiões distintas, que

separam os objetos em três classes de interesse respectivamente.




Figura 8: Diferentes populações sendo agrupadas em classes diferentes.

É importante observar que em problemas reais a fronteira entre regiões não está exatamente definida e sempre haverá superposição, isto é, erro de classificação. O ponto verde e o vermelho na imagem 8 ilustram o problema do erro de interpretação, onde ambos foram classificados em classes errôneas.

3.5 Perceptron Multicamadas - MLP

Redes Neurais Artificiais são métodos computacionais que descrevem um modelo matemático inspirado na estrutura neural humana e que adquirem certo conhecimento através da experiência (MORAIS, 2010). Uma grande rede neural artificial pode ter centenas de unidades de processamento; já o cérebro de um animal pode ter bilhões de neurônios. A principal motivação é a criação de um sistema onde a máquina possa operar independentemente do controle do homem, sendo capaz de interagir com ambientes externos e criar uma própria rotina de aprendizagem.

Em 1943 McCulloch e Pitts publicaram os primeiros artigos sobre o assunto (MORAIS, 2010), eram os primórdios da neuro computação, sugerindo a construção de uma máquina inspirada no cérebro humano. Em 1949, Donald Hebb em seu livro *“The Organization of Behavior”*, propôs uma lei de aprendizagem para a sinapse dos neurônios, porém apesar dos esforços de muitos pesquisadores, a ideia

era incipiente e pouco foi desenvolvido nessa época. Em 1957 e 1958 surgiu o primeiro neuro computador a obter sucesso (Mark I Perceptron), criado por Frank Rosenblatt, Charles Wightman e outros.

A *IEEE International Conference on Neural Networks* ocorreu em 1987 e foi a primeira do gênero, desde então o assunto se consolidou e é amplamente estudado e muito utilizado.

O perceptron Multi Camadas é uma rede neural com retroalimentação, possuindo uma ou mais camadas escondidas (entre as camadas de entrada e saída) (PAPAGELIS; KIM, 2017). Retroalimentação significa que os dados fluem em direção da entrada para a camada de saída. O conceito de neuro computação se baseia no aprendizado humano, e para tal deve simular circuitos que operem de forma similar ao cérebro. Para conceitualizar uma rede neural, pode-se dizer que a mesma é uma grafo direcionado com estrutura de processamento distribuída paralelamente, os nós dos grafos são as unidades de processamento, as arestas são as conexões ou caminhos direcionados que levam a informação de uma unidade até a outra. A entrada da rede se origina de sinais externos e o sinal de saída também flui em sentido ao mundo externo. De forma geral a operação de um neurônio se resume da seguinte forma:

- Sinais chegam até à entrada;
- Cada sinal é multiplicado por um peso que indica sua relevância na saída da unidade;
- O nível de atividade é calculado através da soma ponderada dos sinais;
- A unidade produz uma saída, caso o nível de atividade atinja certo limite.

A arquitetura da rede MLP é basicamente a seguinte: as unidades são divididas em neurônios de entrada, que recebem a informação do meio externo, neurônios escondidos e neurônios de saída que devolve o sinal para o mundo externo. O nome *Multilayer Perpeptron* vem da forma como o arranjo é feito em camadas. A figura 9




Figura 9: Modelo conceitual de uma rede MLP (MIX, 2010).

ilustra a arquitetura básica de uma rede MLP. Na maioria dos casos, as redes MLP possuem regras para o treinamento, de maneira que os pesos de suas conexões são ajustados de acordo com certos padrões e pode-se dizer que eles aprendem através de exemplos. A rede é treinada com dados conhecidos (exemplos), assim, adquirem um protocolo necessário para o tratamento dos dados de entrada. A rede extrai as regras de operação através das amostras reais de teste.

3.5.1 Processos de Aprendizado

O conceito mais relevante de redes neurais é sua capacidade de aprender para melhorar seu desempenho (MORAIS, 2010). Para isso, a rede utiliza um processo iterativo para ajustar os pesos de suas unidades. O aprendizado ocorre quando a rede obtém uma solução genérica para uma classe de problemas. O algoritmo de aprendizagem nada mais é do que um conjunto de regras bem definidas para o problema em questão, onde os pesos são ajustados de forma a minimizar o erro entre a entrada e a saída. Como a rede neural se baseia nos dados para obter o modelo

geral, grande parte dos dados devem ser utilizados para o treinamento da máquina e os mesmos devem ser dispostos de forma aleatória para que a rede aprenda e não decore as regras. Na fase de teste, os dados que não foram apresentados à rede devem ser usados para validação do modelo, de maneira que o classificador possa deduzir corretamente o inter-relacionamento dos dados.

A aprendizagem ocorre no perceptron através da alteração dos pesos entre as conexões. Após o processamento do dado e baseando-se no erro resultante da saída, os pesos são ajustados, esse processo é iterativo e é repetido de acordo com um número pré-estabelecido pelo projetista. Muitas iterações podem resultar em uma máquina lenta e poucas iterações podem ser insuficientes para resolver o problema a ser modelado. Este é um exemplo de aprendizagem supervisionada, e é realizado por meio do algoritmo de *backpropagation*, uma generalização do algoritmo de mínimos quadrados. O Erro é representado matematicamente por pela equação 3.1:

$$\varepsilon = \frac{1}{2} \sum_j e_j^2(n) \quad (3.1)$$

A expressão representa o erro total, dado pela soma individual do erro ao quadrado em cada nó, dividido por dois. O algoritmo de treinamento de uma MLP mais famoso foi proposto por Rumelhart e McClelland em 1986, conhecido como *backpropagation* (retro propagação). O algoritmo visa minimizar o erro quadrático descrito acima. A abordagem é uma das mais utilizadas (PAPAGELIS; KIM, 2017) e um dos métodos mais simples e gerais utilizados para o treinamento supervisionado de redes neurais multicamadas (PAPAGELIS; KIM, 2017). O mecanismo *backpropagation* funciona aproximando-se a relação não-linear entre a entrada e a saída e ajustando-se os valores dos pesos internamente.

3.5.2 Retropropagação

As operações das redes neurais que utilizam *backpropagation* (retropropagação) podem ser divididas em duas etapas: *feedforward* e *backpropagation*. Na etapa *feedforward*, um padrão de entrada é aplicado à primeira camada e seu efeito se propaga, camada por camada através da rede até produzir uma saída. O valor de saída real da rede é comparado com a saída esperada, e um sinal de erro é calculado para cada um dos nós de saída. Uma vez que todos os nós ocultos têm, de certa maneira, contribuído para o erro evidente na camada de saída, os sinais de erro são transmitidos de volta para os neurônios. Esse processo é então repetido, camada a camada, até que cada nó na rede tenha recebido um sinal de erro que descreva a contribuição relativa para o erro geral. Depois que o sinal de erro para cada nó foi determinado, o erro é usado por cada unidade de processamento para recalcular o valor dos pesos nas arestas, de forma a otimizar a solução. O algoritmo *backpropagation* procura o valor mínimo da função de erro no espaço dos pesos, usando uma técnica chamada regra delta ou descida gradiente (*gradient descent*) (PAPAGELIS; KIM, 2017). Os pesos que minimizam a função de erro são então considerados como uma solução para o problema de aprendizagem.

Outro ponto a se considerar é a generalização da rede, quando os dados de treinamento são insuficientes ou há um treinamento demasiado. Quando a rede é simples demais pode apresentar uma solução fraca para o problema. A figura 10 mostra um modelo onde a fronteira de resolução do problema deriva de uma rede muito simples e por isso não consegue atender o requisito de separabilidade das classes de maneira satisfatória. Por outro lado a rede pode ser muito complexa e criar uma solução que esta além dos dados de treino. A figura 11 mostra a situação onde a rede é complexa demais (1) e uma situação hipotética ideal (2).




Figura 10: Solução insuficiente, resultado de uma rede com complexidade muito baixa (PAPAGELIS; KIM, 2017).



Figura 11: Solução apresentada por uma rede muito complexa(1) e solução de uma rede ideal(2) (PAPAGELIS; KIM, 2017).

3.6 Modelo Linear Generalizado - GLM

Os Modelos Lineares Generalizados foram introduzidos por Nelder e Wedderburn nos anos 70 (NELDER; BAKER, 2006), tendo um impacto muito grande no

desenvolvimento da estatística e são extensões dos modelos lineares normais. O conceito inicial consiste em aumentar o leque de opções para a distribuição da variável de resposta, permitindo assim, que ela pertença à família exponencial de distribuições. De maneira geral esses modelos são novos, porém a maioria das soluções estatísticas já contam com módulos adequados a esse modelo. No presente estudo uma nova ferramenta baseada em Modelo Linear Generalizada é utilizada para reconhecimento de padrões do sinal mioelétrico, visando aumentar a fronteira de separabilidade entre as classes e reduzir o tempo necessário para treinamento da rede.

Muitos trabalhos estatísticos objetivam a análise de relação entre as variáveis, onde tal problema é abordado muitas vezes com um modelo de regressão, que relaciona a variável de interesse com as demais variáveis (explícitas). O modelo linear padrão foi desenvolvido no início do século XIX por Gauss e Legendree (MODELOS..., 2017) até hoje possuem uma relevância muito alta, porém frente aos mais variados desafios outros modelos foram propostos - Fisher (LDA, 1922), Bliss (Probit, 1935) entre outros - esses modelos têm em comum uma estrutura de regressão linear e a variável de resposta pertence a uma distribuição exponencial. Os modelos introduzidos por Nelder e Wedderburn são uma síntese de diversos outros, sendo casos particulares dos modelos GLM:

- Modelo de regressão logística;
- Modelo de regressão de Poisson;
- Modelos de análise de variância e covariância;
- Modelo de regressão linear clássico.

4 Plataforma de Reconhecimento de Padrões

Antes da construção de um sistema de *hardware* capaz de reconhecer os movimentos relativos a cada sinal, é necessário simular e testar algoritmos de reconhecimento de padrões em sistemas de *software*, porém, tais sistemas têm sido construídos por diferentes grupos de pessoas e universidades, tendo assim seu acesso restrito. Max Ortiz-Catalan, professor na unidade de pesquisa da *Biomedical Signals and Systems*, no esforço de criar uma plataforma comum onde os pesquisadores possam modelar diversos tipos de soluções para desenvolvimento de próteses, criou a plataforma BioPatRec (ORTIZ-CATALAN; BRANEMARK; HAKANSSON, 2013). O trabalho trata-se de uma interface de *software* de código aberto, onde diversas abordagens podem ser criadas e testadas, antes de serem embarcadas em um braço mecânico.

Os textos presentes em algumas imagens ilustrativas se encontram em inglês, visto que, são imagens do *software* e este ainda não possui uma versão em português.

4.1 BioPatRec

BioPatRec é uma plataforma de código livre para processamento e gravação de sinal mioelétrico, seleção e extração de características, reconhecimento de padrões e controle em tempo real de prótese, cujo o intuito é fornecer um ambiente centrali-

zado onde os pesquisadores possam trabalhar em soluções para o desenvolvimento e melhoramento de sistemas de reabilitação para pessoas que nasceram com algum tipo de má formação ou que tiveram algum trauma.

Possui um ambiente de realidade virtual para avaliação qualitativa e quantitativa de algoritmos de reconhecimento de padrões descritos nesse trabalho, dentre outros algoritmos. Além do mais, a plataforma é modular e personalizável, o que viabiliza diferentes estudos e foi escrita na linguagem Matlab. Tal plataforma foi utilizada para avaliação e teste do presente trabalho. A imagem da figura 12 mostra o diagrama de funcionamento da ferramenta.

O *software* é gratuitamente disponibilizado no site de Ortiz-Catalan (2017) e também conta com uma ampla documentação.



Figura 12: Diagrama de blocos que ilustra o funcionamento geral da plataforma BioPatRec (ORTIZ-CATALAN, 2017).

4.2 Gravação do Sinal

BioPatRec permite a gravação de sinais bioelétricos através de alguns dispositivos pré-configurados (NI-USB6009) e permite que outros dispositivos de gravação sejam adicionados ao seu repositório pelos desenvolvedores. Os sinais podem ser gravados para avaliação dos mesmos, para um futuro processamento ou para controle em tempo real. Para isso, a ferramenta conta com uma interface gráfica (GUI) que facilita o trabalho. A figura 13 ilustra os parâmetros que devem ser configurados antes da gravação (tempo de contração, relaxamento e número de repetições) e a figura 14 mostra o sinal resultante da gravação.

A sessão de gravação mostra quais movimentos devem ser executados através de uma sequência de imagens, configura os tempos necessários para contração e relaxamento muscular entre os movimentos e orienta o indivíduo com relação ao

esforço muscular que está sendo empregado na realização dos movimentos, para isso, a plataforma executa um cálculo entre o esforço mínimo e o esforço máximo. Este módulo da plataforma também permite que os dados sejam adquiridos por até 4 canais diferentes. Esse trabalho utilizou um conjunto de sinais obtidos no repositório do BioPatRec ao invés de coletar as amostras de indivíduos que tiveram algum trauma.

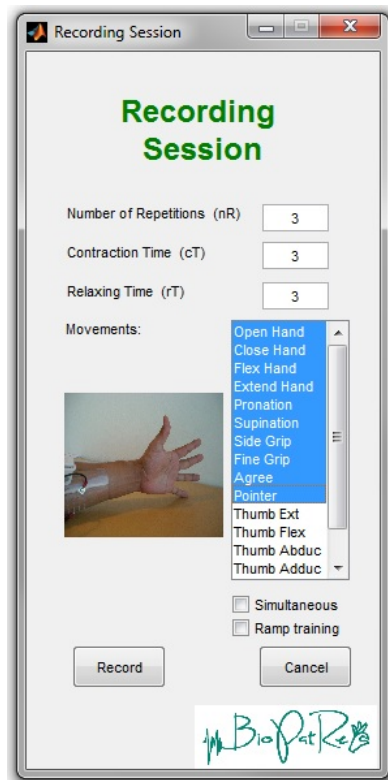


Figura 13: Ajuste dos parâmetros antes da gravação (ORTIZ-CATALAN, 2017).

4.3 Tratamento do Sinal

Os algoritmos de classificação não são alimentados diretamente com os sinais mioelétricos e sim com características extraídas dos mesmos, para tal, antes de extraí-las é necessário um tratamento prévio do sinal a fim de se reduzir os artefatos indesejados. A ferramenta conta com uma interface para esse trabalho, onde é

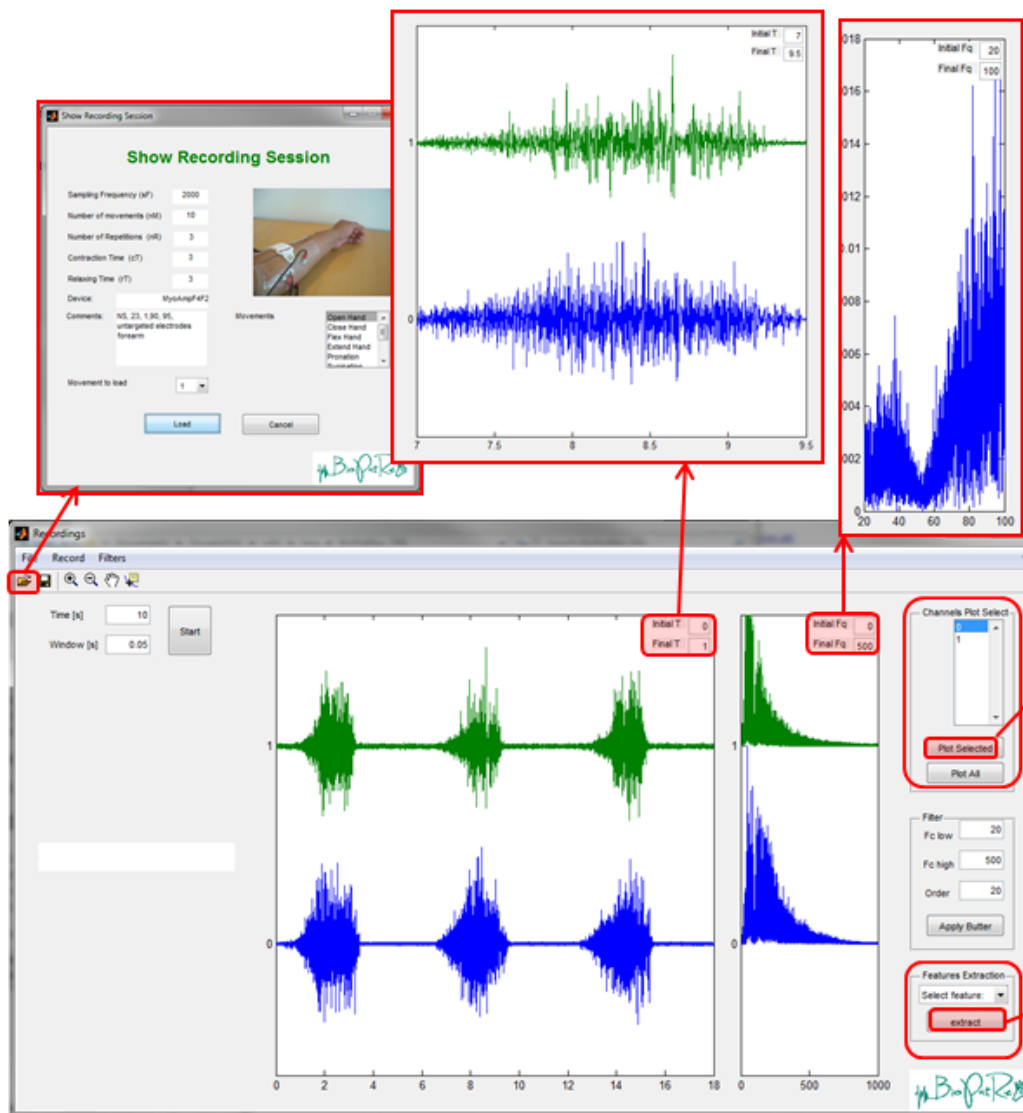


Figura 14: Sinal gravado resultante (ORTIZ-CATALAN, 2017).

possível: a remoção de canais ou movimentos que não são de interesse para o estudo, remoção de períodos transientes da contração muscular (através da seleção da porcentagem da contração desejada), a re-amostragem da frequência e aplicação de filtros como diferencial simples (SDF), diferencial dupla (DDF) ou passa faixa. Também é possível redimensionar o tamanho das janelas de onde as características são extraídas (JIANG et al., 2012b). Estas são apenas algumas das características

disponíveis para o pré tratamento do sinal. A figura 15 mostra as funcionalidades para esse módulo, onde é possível a aplicação de filtros e a escolha do tamanho dos conjuntos de treino, validação e testes. Para esse trabalho esses ajustes foram deixados na configuração padrão. A figura 16 ilustra duas possíveis configurações para o ajuste das janelas, para o estudo utilizou-se a configuração não sobreposta.

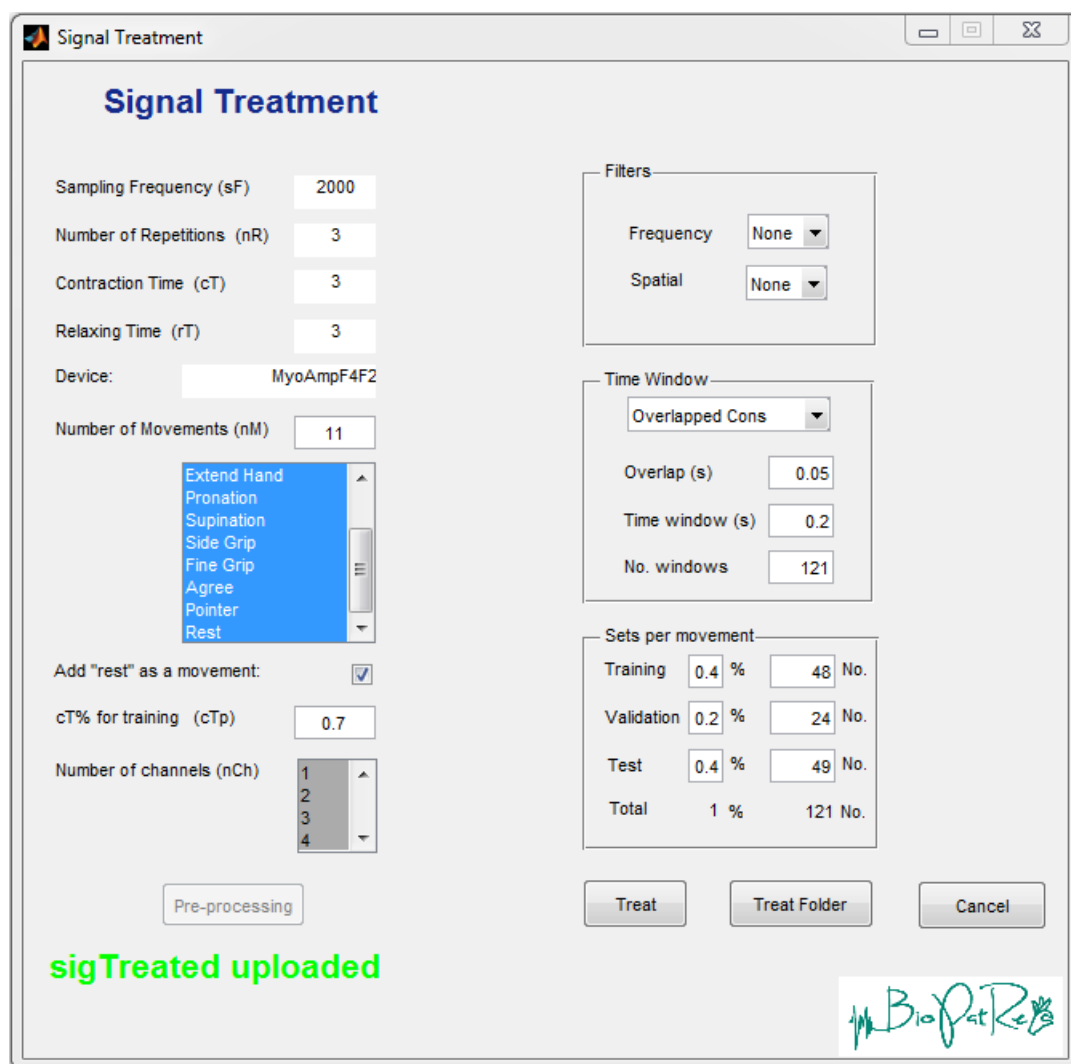


Figura 15: Interface para o tratamento do sinal. É possível fazer a re-amostragem do sinal, aplicação de filtros e definição do tamanho das janelas de características (ORTIZ-CATALAN, 2017).




Figura 16: Duas configurações possíveis para as janelas de características: sobrepostas ou janelas sequenciais (ORTIZ-CATALAN, 2017).

4.4 Extração de Características

O *software* conta com a possibilidade de extração de 27 características diferentes, com algumas no domínio do tempo e outras no domínio da frequência. Dessa forma é possível criar várias combinações antes de alimentar a máquina. Também é possível que um conjunto novo de características seja criado e adicionado à plataforma. Muitos trabalhos foram feitos no sentido de se encontrar um conjunto ideal de características para alimentar tais máquinas como em (ENGLEHART et al.,

1999). A ferramenta permite o estudo individual de cada uma delas, onde é possível mensurar o tempo gasto e a acurácia obtida. Algumas das características que a plataforma permite a extração são:

- *tmabs: Mean absolute value* - Domínio do tempo;
- *tstd: Standard deviation* - Domínio do tempo;
- *trms: RMS* - Domínio do tempo;
- *tzc: Zero-crossing* - Domínio do tempo;
- *tzc: Zero-crossing* - Domínio do tempo;
- *twl: Waveform length* - Domínio do tempo;
- *fwl: Waveform length* - Domínio da frequência;
- *fpmn: Peaks mean* - Domínio da frequência.

4.5 Reconhecimento de Padrões

O último módulo relevante para esse estudo é o de reconhecimento de padrões, após o tratamento do sinal e devida extração de características é possível criar uma estratégia para reconhecimento e avaliar se a técnica é boa ou ruim. A ferramenta também conta com um módulo estatístico que facilita a avaliação da estratégia e organização dos resultados. Os seguintes classificadores já vêm incorporados no BioPatRec:

- LDA - *Discriminant Analysis*;
- MLP - *Multi-layers Perceptron*;
- KNN - *k-Nearest Neighbor Semi*;

- RFN - *Regulatory Feedback Networks*;
- SOM - *Self-Organizing Map*;
- SSOM - *Supervised Self-Organizing Map*.
- Netlab GLM
- Netlab MLP

Além do mais, a estratégia pode ser avaliada em tempo real ou *offline*, isto é, com os dados amostrados na hora, na presença de um indivíduo que teve algum tipo de trauma ou com dados pré gravados. A figura 17 apresenta a interface gráfica da plataforma para reconhecimento de padrões e análise dos resultados. Onde é possível escolher entre os diferentes algoritmos de treino, conjuntos de características e tipos de normalização. A figura 17 mostra o ambiente de teste onde diversas abordagens podem ser testadas, após a configuração selecionada é possível verificar os resultados da acurácia e do tempo.

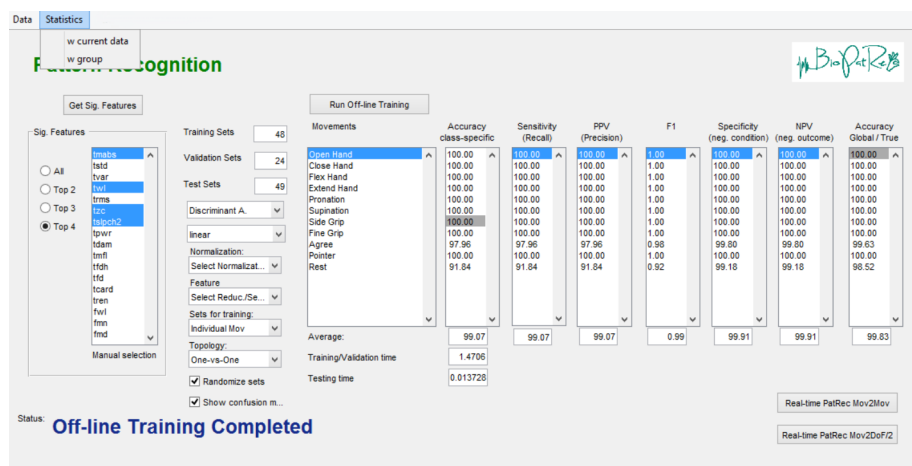


Figura 17: Interface gráfica para reconhecimento de padrões (ORTIZ-CATALAN, 2017).

Após a extração de características, a matriz resultante da operação pode ser organizada de diferentes maneiras, isso afeta a forma como os dados são usados para o treinamento e teste da rede, as opções são:

- *All Mov*: Nessa configuração os movimentos são sempre tratados como independentes, ou seja, independente de serem movimentos individuais ou a combinação de dois ou mais movimentos. Quando um movimento é individual diz-se que este possui um grau de liberdade, no caso onde o movimento é uma combinação de dois movimentos individuais (rotação e flexão) diz-se que o mesmo possui dois graus de liberdade.
- *Individual Mov*: Para essa opção a rede só irá considerar os movimentos individuais durante a fase de treino e todos os movimentos durante a fase de teste.
- *Mixed Out*: O BioPatRec considera um misto de movimentos na fase de treino, ou seja, tanto movimentos individuais e simultâneos são apresentados à máquina nessa fase.

Outros parâmetros como normalização dos conjuntos de treino e arranjo da topologia da rede também podem ser escolhidos na fase de configuração da rede.

O BioPatRec apresenta outras funcionalidades que vão além daquelas apresentadas até aqui. Como o estudo utilizou um conjunto de sinais já gravados, as ferramentas para análise em tempo real não foram utilizadas e por isso não serão apresentadas.

5 Trabalho Desenvolvido

Netlab MLP, Netlab GLM e LDA foram escolhidos para esse estudo por apresentarem bons resultados no trabalho apresentado em (ORTIZ-CATALAN et al., 2016) a respeito do tempo e da acurácia e por apresentarem resultados relativamente melhores a outros algoritmos disponíveis na plataforma BioPatRec. Pretende-se investigar em qual faixa de operação os classificadores mencionados apresentam melhores resultados, quando certas configurações de cada algoritmo são alteradas. Basicamente o trabalho consiste em:

- Aquisitar o sinal: O sinal pode ser gravado através da plataforma BioPatRec, utilizando-se um dispositivo pré-configurado, ou pode ser obtido através de um repositório comum, através do site do fabricante.
- Tratamento do sinal: Após a coleta do sinal, o mesmo deve ser tratado, a ferramenta conta com alguns filtros que permitem ao desenvolvedor remover artefatos indesejados do mesmo.
- Re-amostragem do sinal: Também é possível realizar a re-amostragem do sinal com um determinado número de pontos de interesse, isso permite ao desenvolvedor generalizar o sinal.
- Extração de características: Nessa etapa é possível escolher quais características serão extraídas do sinal antes de alimentar cada classificador (nenhum algoritmo é alimentado diretamente com o sinal). É possível utilizar um conjunto de características personalizado.

- Escolha do classificador: Nessa etapa o desenvolvedor deve escolher dentre os algoritmos de classificação disponíveis na plataforma.
- Ajuste do classificador: Cada classificador tem uma gama de parâmetros que podem ser ajustados antes da classificação e estão estritamente relacionados à qualidade dos resultados.
- Avaliação dos resultados: Os testes devem ser repetidos diversas vezes, para que possa haver um tratamento estatístico e uma futura conclusão a respeito de determinada abordagem.

5.1 Aquisição dos Sinais

Para facilitar o presente estudo nenhum sinal foi diretamente gravado, utilizou-se de um determinado conjunto de sinais pré-gravados. Entre os arquivos disponíveis no repositório de sinais BioPatRec, o utilizado foi *10mov4chUntargetedForearm*.

Estes sinais foram coletados de 20 pessoas que não possuíam nenhum tipo de malformação congênita e não sofreram nenhum trauma. Cada sinal contém dados relacionados a onze movimentos (abrir e fechar a mão, flexão e extensão do pulso, pronação e supinação, aperto de mão, movimento de pinça com os dedos, apontar, concordar e descansar, que são de interesse para o reconhecimento de padrões. Cada movimento foi coletado em um intervalo de 3 segundos, com 3 segundos de descanso. Todos os movimentos foram repetidos 3 vezes. Os dados foram adquiridos por 4 eletrodos Ag/AgCl com 1 centímetro de diâmetro e separados 2 centímetros.

5.2 Re-amostragem do Sinal

Como o conjunto de sinais obtidos do site do BioPatRec possuía uma quantidade relativamente grande de pontos, quer-se verificar se é possível generalizar o sinal segundo os critérios de Nyquist e obter algum ganho de desempenho, quando

o algoritmo Netlab MLP é alimentado por um sinal genérico ao invés da amostra original.

Um sinal limitado em banda é condicionado pela velocidade de sua variação no tempo, assim, a quantidade de informação que pode ser transmitida em um intervalo de tempo depende dessa variação. O teorema de amostragem diz que as amostras discretas uniformemente espaçadas são uma representação completa do sinal se sua largura de banda for inferior a metade da taxa de amostragem (NYQUIST, 1928), (SHANNON, 1949). Seja, $x(t)$ a representação de um sinal contínuo no tempo e seja $X(f)$ sua transformada de Fourier, conforme descrito na equação 5.1:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-i2\pi ft} dt \quad (5.1)$$

A condição suficiente para uma reconstrução exata das amostras com uma taxa de amostragem uniforme fs onde B é o limite da banda é descrito como na equação 5.2:

$$f(s) > 2B \quad (5.2)$$

Verificou-se a condição acima com o uso da Transformada Rápida de Fourier do Matlab[®]. A figura 18 representa o espectro de frequência do sinal 1, sendo a maior frequência em torno de 450 Hz. A mesma análise foi feita para os 19 sinais restantes e as bandas de frequência encontradas no conjunto de sinais ficaram em torno de 450Hz à 500Hz.

Pelo teorema de Nyquist seriam necessárias 900 (2B) amostras por segundo para representação discreta do sinal mioelétrico. Como o sinal adquirido foi obtido em 18 segundos, logo, uma reconstrução completa do sinal gastaria em torno 18000 pontos. O conjunto de dados original possui 36000 pontos, quer-se re-amostrar os sinais originais com uma quantidade menor de dados, verificar se não há perda de acurácia e se é possível obter algum ganho quando os classificadores são ali-

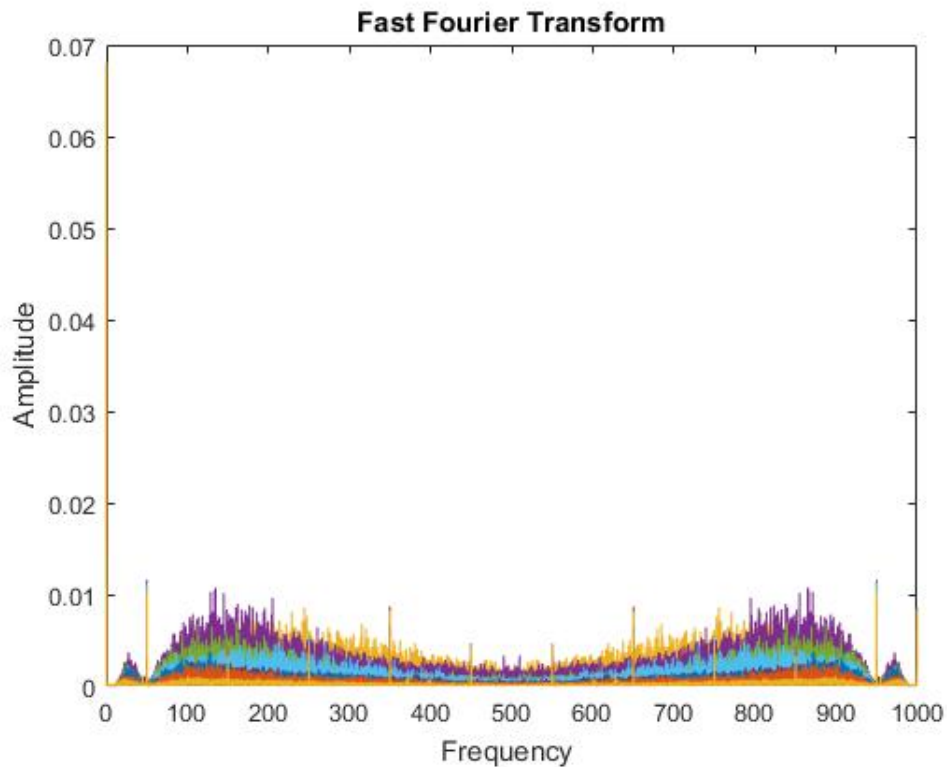
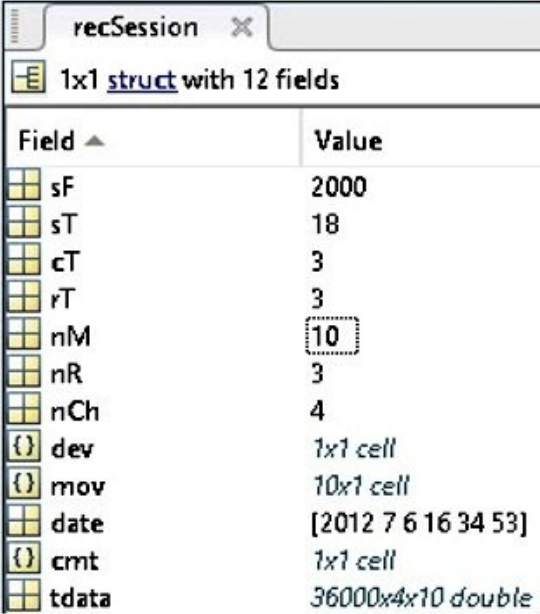


Figura 18: Transformada de Fourier do sinal 1. A maior frequência fica em torno de 450 Hz, o lado direito da imagem é um espelho do resultado, imagem obtida com auxílio do Matlab.

mentados com um sinal genérico. A ideia é reduzir a quantidade de informação que chega até a rede sem perda de relevância. Cada sinal obtido da plataforma BioPatRec é uma estrutura de dados com os elementos da figura 19. A estrutura de dados do sinal re-amostrado possui as características da figura 20. Os itens em ambas figuras representam respectivamente:

- sF : Frequência de amostragem;
- sT : Tempo de amostragem;
- cT : Tempo de contração;
- sT : Tempo de relaxamento;

- nM : Número de movimentos;
- nR : Número de repetições;
- nCh : Número de canais;
- $tdata$: Vetor com o sinal coletado.



| Field ▲ | Value |
|---------|---------------------|
| sF | 2000 |
| sT | 18 |
| cT | 3 |
| rT | 3 |
| nM | 10 |
| nR | 3 |
| nCh | 4 |
| dev | 1x1 cell |
| mov | 10x1 cell |
| date | [2012 7 6 16 34 53] |
| cmt | 1x1 cell |
| tdata | 36000x4x10 double |

Figura 19: Estrutura de dados do sinal original na plataforma BioPatRec, obtida com o Matlab.

| Field ▲ | Value |
|---------|---------------------|
| sF | 1000 |
| sT | 18 |
| cT | 3 |
| rT | 3 |
| nM | 10 |
| nR | 3 |
| nCh | 4 |
| dev | 1x1 cell |
| mov | 10x1 cell |
| date | [2012 7 6 16 34 53] |
| cmt | 1x1 cell |
| tdata | 18000x4x10 double |

Figura 20: Estrutura de dados do sinal re-amostrado, obtida com o Matlab.

5.3 Classificador Netlab MLP

O modelo não-linear Netlab MLP foi escolhido porque apresentou um tempo de treinamento menor do que outras redes neurais artificiais (ANN) e maior precisão na predição dos resultados, apesar de ter um custo efetivo maior (ORTIZ-CATALAN; HAKANSSON; BRANEMARK, 2007). Para o estudo, o número ótimo de neurônios foi avaliado em relação ao número de iterações que a rede executa. O algoritmo também foi testado com dois sinais diferentes, o sinal original e o sinal re-amostrado com a metade dos pontos. A generalização do sinal foi feita de forma semelhante pelo estudo (GUANGLIN et al., 2011), e pretende-se avaliar se houve qualquer inferência nos resultados neste ambiente, visto que, em sistema embarcado de uma prótese real a quantidade de dados e a generalização dos mesmos podem ser um fator limitante para o funcionamento.

A rede Netlab MLP permite a configuração de alguns parâmetros como número de iterações, neurônios na camada escondida e a função de ativação da unidade de

saída (*linear*, *logistic* e *softmax*). A função de ativação escolhida para os testes foi a *softmax*, pois a mesma apresentou melhores resultados com relação a acurácia nos testes iniciais.

5.4 Classificador Netlab GLM

De acordo com Ortiz-Catalan, Branemark e Hakansson (2013), os principais benefícios de métodos como LDA e GLM são sua baixa complexidade e treinamento rápido, a MLP sendo uma ANN depende do treinamento específico para medir seus resultados. O classificador Netlab GLM foi avaliado por outro estudo (ORTIZ-CATALAN; BRANEMARK; HAKANSSON, 2013), mas não ficou inteiramente claro qual a configuração de rede utilizada.

No presente estudo, o algoritmo é testado em três cenários diferentes. A primeira avaliação é feita em relação ao algoritmo de otimização usado: gradiente conjugado escalonado (scg) ou mínimos quadrados iterativamente ponderados (irls). O segundo critério de avaliação é o número máximo de iterações que a rede pode executar, uma vez que a acurácia e o tempo de treinamento estão diretamente ligados a isso, pretende-se avaliar o número ótimo de ciclos. Assim como a rede MLP a função de ativação escolhida foi a *softmax* devido aos mesmos critérios mencionados no item anterior.

5.5 Classificador LDA

Devido aos requisitos de desempenho exigidos por um sistema em tempo real, o classificador LDA (*Linear Discriminant Analysis*), com baixa complexidade de implementação e baixo tempo de treinamento foi escolhido como um critério de comparação para este estudo, e é usado pelos pesquisadores em (SCHEME; ENGLEHART; HUDGINS, 2011), (AMSUSS et al., 2013), no entanto, não garante a melhor precisão nos resultados (AMSUSS et al., 2013). Além disso, o algoritmo clássico foi testado

com diferentes grupos de características, de acordo com o protocolo do item 5.7. A ideia é conseguir uma redução dimensional que permita o funcionamento de um sistema em tempo real, sem prejudicar a acurácia na previsão dos movimentos e capaz de treinar a rede quantas vezes for necessário ao longo do dia. A função utilizada para esse teste foi a *classify* do Matlab[®], o *software* conta com outros tipos mais complexos da mesma função, porém ainda não foram implementados na ferramenta. É possível escolher entre diferentes tipos de funções discriminantes, dentre as quais:

- *Linear*: É a opção padrão. Ajusta uma densidade normal para cada grupo, com uma estimativa agregada de covariância;
- *Diaglinear*: É similar a função linear, mas usa uma matriz diagonal de covariância para fazer a estimação;
- *Quadratic*: Adapta-se a densidades normais multivariadas com estimativas de covariância estratificadas por grupo. Essa opção foi utilizada para esse classificador, pois apresentou os melhores resultados nos testes iniciais, em comparação com as demais;
- *Diaquadratic*: É similar a função *quadratic*, mas usa uma matriz diagonal de covariância para fazer a estimação;
- *Mahalanobis*: Usa distâncias de Mahalanobis com estimativas de covariância estratificada. Também apresenta bons resultados para reconhecimento de padrões do sinal mioelétrico.

5.6 Conjunto de Características

Os algoritmos de classificação são alimentados com determinados conjuntos de características (no domínio do tempo ou da frequência) extraídos do sinal mioelétrico. Muitos trabalhos, como (ENGLEHART et al., 1999), foram feitos a fim de

estudar o impacto dessas características no sistema. Neste estudo, uma abordagem simples para avaliá-los foi feita com o objetivo de se obter uma redução de dimensionalidade, visando uma melhora no tempo e sem perda relativa de acurácia.

A contribuição de cada conjunto de características fornecido pelo BioPatRec foi avaliada individualmente para cada um dos classificadores, de modo que os cinco melhores em relação ao tempo e precisão foram selecionados. Um pouco diferente da documentação do BioPatRec, as características selecionadas foram: cardinalidade (tcard), comprimento de onda (twl), valor absoluto médio (tmabs), cruzamento zero (tzc) e mudanças de inclinação (tslpch2). Como o uso individual de cada característica não apresenta bons resultados em relação à precisão da classificação, o seguinte cenário de teste foi montado. Usando os dois conjuntos com as melhores avaliações individuais (tcard e twl), usando os cinco apresentados acima e com todos os conjuntos disponíveis na plataforma. O modelo não-linear Netlab MLP foi avaliado apenas com todos os conjuntos disponíveis, devido ao grande número de possibilidades a serem testadas.

5.6.1 Cardinalidade

A cardinalidade é definida como o número de elementos únicos em um conjunto e foi introduzida por Ortiz-Catalan (2015) como conjunto de característica do sinal mioelétrico capaz de melhorar a acurácia dos classificadores, em detrimento de outros como alguns apresentados por (HUDGINS; HUDGINS; SCOTT, 1991). Diferente de outros conjuntos como valor absoluto médio (tmabs) ou cruzamento de zeros (zc) a cardinalidade não é afetada pelos deslocamentos da componente contínua (DC) que é causada pelo desajuste da impedância dos eletrodos (HARGROVE; ENGLEHART; HUDGINS, 2008). Além do estudo citado, verificou-se que quando os algoritmos de reconhecimento de padrões eram alimentados apenas pela cardinalidade, os mesmos eram capazes de obter altas acurácias em comparação com outros conjuntos de características.

5.6.2 Cruzamento de Zero

O conjunto de características Cruzamento de Zero apenas computa o número de vezes que a onda cruzou o zero e quando isso ocorreu. Esse conjunto já é bem conhecido e também é utilizado por outras áreas do conhecimento como processamento digital de voz.

5.6.3 Comprimento de Onda

O comprimento de onda representa uma oscilação completa no espaço da posição. É a distância paralela à direção em que a onda se propaga, entre repetições da forma de onda (COMPRIMENTO..., 2017).

5.6.4 Valor Absoluto Médio

O valor absoluto médio de um sinal é a distância média entre cada ponto do sinal e a média. Isso nos dá uma ideia sobre a variabilidade do conjunto. Uma estimativa do valor absoluto médio do sinal x no segmento i com amostras de comprimento L é dado por:

$$\bar{x}_i = \frac{1}{L} \sum_{k=1}^L |x_k| \text{ para } i = 1, \dots, I \quad (5.3)$$

Onde x_k representa a k -ésima amostra no segmento i e I é o número total de segmentos.

5.7 Planejamento do Experimento

Os testes foram divididos em três baterias diferentes, a primeira pretende investigar se há algum ganho ou perda quando a máquina é alimentada com um sinal re-amostrado em detrimento do sinal original. O classificador usado para

essa comparação foi o Netlab MLP, pois apresentou os melhores resultados com relação a predição dos movimentos em outro estudo (ORTIZ-CATALAN et al., 2016), mas com os piores tempos de treino. A figura 21 resume o protocolo de testes para esse conjunto de avaliação. Como a alta acurácia é a métrica desejada para esse classificador, o número de iterações variou de 50 até 400 (50, 100, 200 e 400).

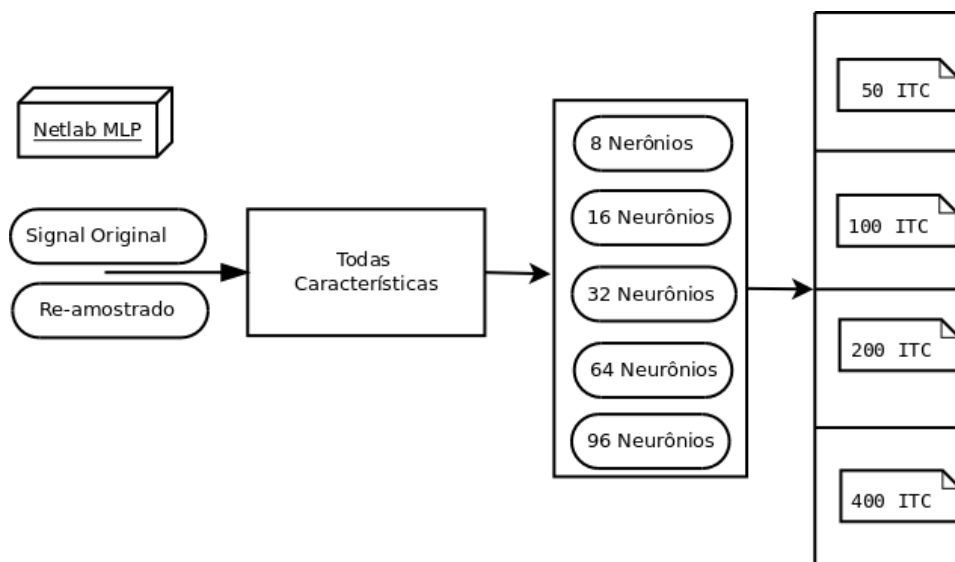


Figura 21: Netlab MLP alimentado pelo sinal original e re-amostrado. Variou-se o número de neurônios e iterações da rede para se obter uma relação de desempenho do algoritmo em diferentes casos.

O segundo conjunto de teste foi feito em relação aos dois modelos lineares Netlab MLP (scg) e Netlab MLP (irls). Como os modelos citados não possuem neurônios em sua implementação, os testes foram feitos em relação aos conjuntos de características que chegam à rede e ao número máximo de iterações que o classificador pode realizar. Nesse caso, o número de ciclos variou de 25 a 200, pois estamos interessados em fazer o trabalho no menor tempo possível. A figura 22 resume o protocolo para esses testes.

E, finalmente, o classificador LDA foi avaliado com relação aos conjuntos de características que o alimenta. A figura 23 mostra o esquema de teste para esse algoritmo.

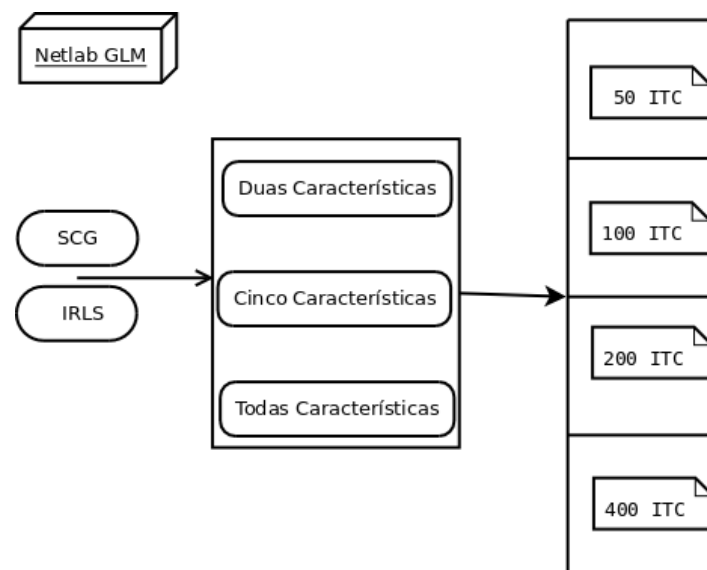


Figura 22: Os dois algoritmos otimizados de treino do Netlab GLM são avaliados com relação ao número de iterações e conjuntos de características que alimentam os mesmos.

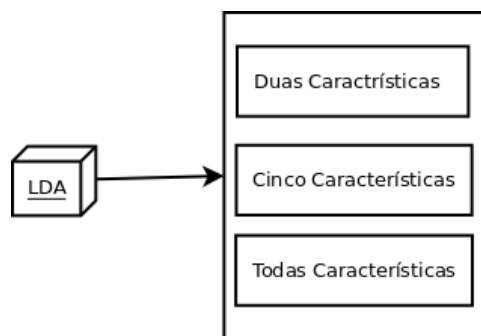


Figura 23: Modelo linear clássico alimentado por diferentes grupos de características.

5.8 Tratamento do Sinal

Todos os sinais obtidos no repositório foram tratados pelos seguintes filtros: passa alta de quarta ordem com uma frequência de corte de 20 Hz, passa baixa de segunda ordem com uma frequência de corte de 400 Hz e um filtro *notch* de 50 Hz. Os sinais foram amostrados com uma frequência de 2 KHz, de acordo com a metodologia de Ortiz-Catalan, Branemark e Hakansson (2013)

5.9 Ambiente de Teste

Os testes foram realizados em uma máquina com as seguintes configurações: processador Intel Core i7 de 2,3 GHz, 4 GB de RAM e SSDHD de 128 GB. O ambiente de simulação contou com Windows 10, Matlab[®] e BioPatRec.

5.10 Análise Estatística

Para cada um dos 20 sinais adquiridos, foram realizadas 10 replicações de cada, o que gerou um conjunto de teste com 200 execuções. Para a primeira bateria foram necessários (2 sinais diferentes, 5 configurações de neurônios e 4 grupos de iterações) 40 testes, o que resulta em 8000 simulações. Para o segundo caso, foram realizados um total de 24 testes (2 algoritmos otimizados, 3 grupos de características e 4 conjuntos de iterações), resultando em 4800 simulações. Para a avaliação do LDA, apenas 3 cenários foram avaliados, resultando em 600 simulações. Os dados calculados foram a acurácia específica e o tempo de treinamento. O experimento foi conduzido da seguinte maneira: cada indivíduo realizou uma execução do programa, após o término das 20 execuções (20 indivíduos) calculou-se a média geral, essa média foi considerada como valor da primeira iteração. Esse procedimento foi repetido 10 vezes, o que gerou 10 médias diferentes. Com esses 10 valores calculou-se a média geral de um dos experimentos (Netlab MLP - 200 Neurônios com 100 Iterações), bem como o desvio padrão e o intervalo de confiança. O tamanho da amostra utilizada (10 replicações) foi escolhida de acordo com o protocolo utilizado por outros autores em trabalhos semelhantes como em (ORTIZ-CATALAN; HAKANSSON; BRANEMARK, 2007), o presente estudo não fez uma abordagem própria para o cálculo desse valor e também não encontrou na bibliografia detalhes de como esse valor foi obtido. O experimento considerou a média e o desvio padrão para a acurácia e o tempo de treinamento. Os intervalos de confiança acompanham os gráficos. O teste t pareado foi usado para obter as diferenças estatísticas entre as médias dos valores comparados. O teste t é utilizado para testar se há diferença

entre duas amostras. Para esse trabalho ele foi empregado para verificar se a rede Netlab MLP apresentava diferença estatística quando alimentada por um sinal reamostrado em detrimento do sinal original. A diferença estatística foi considerada como $p < 0.05$ para esse teste.

6 Resultados

Os resultados são definidos de acordo com o desempenho de cada um dos classificadores, conforme o protocolo de teste. O objetivo é obter uma configuração ideal para cada caso e fazer algumas comparações de desempenho. Os resultados dos intervalos de confiança acompanham os gráficos das respectivas figuras.

6.1 Netlab MLP

O estudo (ORTIZ-CATALAN et al., 2016) obteve uma precisão de $(98.3\% \pm 2.4\%)$ com tempo de 1.82 segundos, usando o sinal original e um protocolo de teste onde o número de unidades escondidas da rede MLP foram 32 e o número de iterações máximas foram 200. O estudo utilizou um conjunto de dados referentes a 17 pessoas. Para essa dissertação foi utilizado um conjunto de dados referentes a 20 pessoas, visto que, o conjunto original não estava mais disponível nos repositórios BioPatRec. Para critério de comparação, o presente trabalho obteve uma acurácia de $(96,47\% \pm 0.23\%)$ com tempo de 2,13, onde o número de iterações foram 200 e o número de neurônios na camada escondida foram 32. A diferença pode ser justificada devido ao conjunto de dados diferente e a configuração do ambiente onde os testes ocorreram (sistema operacional ou versão do software). A tabela 1 apresenta os resultados para o classificador Netlab MLP para o sinal original e a tabela 2 mostra os resultados para o sinal re-amostrado.

Tabela 1: Netlab MLP - Sinal Original

| | Iterações | Acurácia(%) | DP | Tempo(s) | DP |
|---------------------|------------------|--------------------|-----------|-----------------|-----------|
| 8 Neurônios | 50 | 92.01 | 0.84 | 0.77 | 0.01 |
| | 100 | 94.27 | 0.62 | 1.06 | 0.01 |
| | 200 | 94.70 | 0.22 | 1.44 | 0.03 |
| | 400 | 94.53 | 0.31 | 2.43 | 0.06 |
| 16 Neurônios | 50 | 94.59 | 0.32 | 0.87 | 0.01 |
| | 100 | 95.88 | 0.21 | 1.22 | 0.01 |
| | 200 | 96.09 | 0.22 | 1.73 | 0.04 |
| | 400 | 96.23 | 0.32 | 2.43 | 0.04 |
| 32 Neurônios | 50 | 95.20 | 0.22 | 0.97 | 0.01 |
| | 100 | 96.33 | 0.20 | 1.38 | 0.02 |
| | 200 | 96.72 | 0.21 | 2.06 | 0.02 |
| | 400 | 96.83 | 0.14 | 2.57 | 0.07 |
| 64 Neurônios | 50 | 95.08 | 0.15 | 1.11 | 0.02 |
| | 100 | 96.16 | 0.17 | 1.78 | 0.02 |
| | 200 | 96.68 | 0.19 | 2.65 | 0.06 |
| | 400 | 96.90 | 0.16 | 3.26 | 0.01 |
| 96 Neurônios | 50 | 95.14 | 0.13 | 1.34 | 0.01 |
| | 100 | 95.75 | 0.20 | 2.07 | 0.02 |
| | 200 | 96.51 | 0.20 | 3.17 | 0.05 |
| | 400 | 96.87 | 0.26 | 4.01 | 0.14 |

A figura 24 mostra que a acurácia é diretamente proporcional ao número de iterações realizadas pela rede e ao número de neurônios na camada oculta. Além disso, há uma saturação dos resultados quando os ciclos ultrapassam 200 e o número de neurônios é superior a 32.

Tabela 2: Netlab MLP - Sinal Re-amostrado

| | Iterações | Acurácia(%) | DP | Tempo(s) | DP |
|---------------------|-----------|-------------|------|----------|------|
| 8 Neurônios | 50 | 91.50 | 0.28 | 0.81 | 0.01 |
| | 100 | 93.89 | 0.26 | 1.06 | 0.02 |
| | 200 | 94.04 | 0.24 | 1.63 | 0.03 |
| | 400 | 94.65 | 0.31 | 2.46 | 0.05 |
| 16 Neurônios | 50 | 94.36 | 0.21 | 0.86 | 0.01 |
| | 100 | 95.48 | 0.23 | 1.20 | 0.01 |
| | 200 | 95.77 | 0.12 | 1.81 | 0.02 |
| | 400 | 95.76 | 0.26 | 2.32 | 0.04 |
| 32 Neurônios | 50 | 94.81 | 0.27 | 0.99 | 0.03 |
| | 100 | 95.84 | 0.20 | 1.39 | 0.02 |
| | 200 | 96.47 | 0.23 | 2.17 | 0.02 |
| | 400 | 96.58 | 0.28 | 2.59 | 0.05 |
| 64 Neurônios | 50 | 94.71 | 0.24 | 1.14 | 0.02 |
| | 100 | 95.80 | 0.21 | 1.80 | 0.02 |
| | 200 | 96.51 | 0.13 | 2.61 | 0.05 |
| | 400 | 96.55 | 0.12 | 3.10 | 0.08 |
| 96 Neurônios | 50 | 94.74 | 0.24 | 1.33 | 0.01 |
| | 100 | 95.46 | 0.27 | 2.01 | 0.04 |
| | 200 | 96.42 | 0.19 | 3.13 | 0.05 |
| | 400 | 96.58 | 0.23 | 3.69 | 0.13 |




Figura 24: Relação de desempenho quando a medida é a precisão na predição dos movimentos. A qualidade dos resultados aumenta à medida que a complexidade da rede aumenta.

Quando a medida de interesse é o tempo, os padrões são inversos, ou seja, quanto maior o número de iterações e neurônios, mais tempo é necessário para treinar a rede, o que é indesejável para os sistemas de reconhecimento de padrões de sinais mioelétricos. A figura 25 mostra essa relação. Observou-se também que quanto menor é o número de neurônios maior é o desvio padrão para esse classificador (acurácia), ou seja, a capacidade de distinção entre as classes corretas varia mais em um máquina com 8 nerônios ao invés de uma com 32.

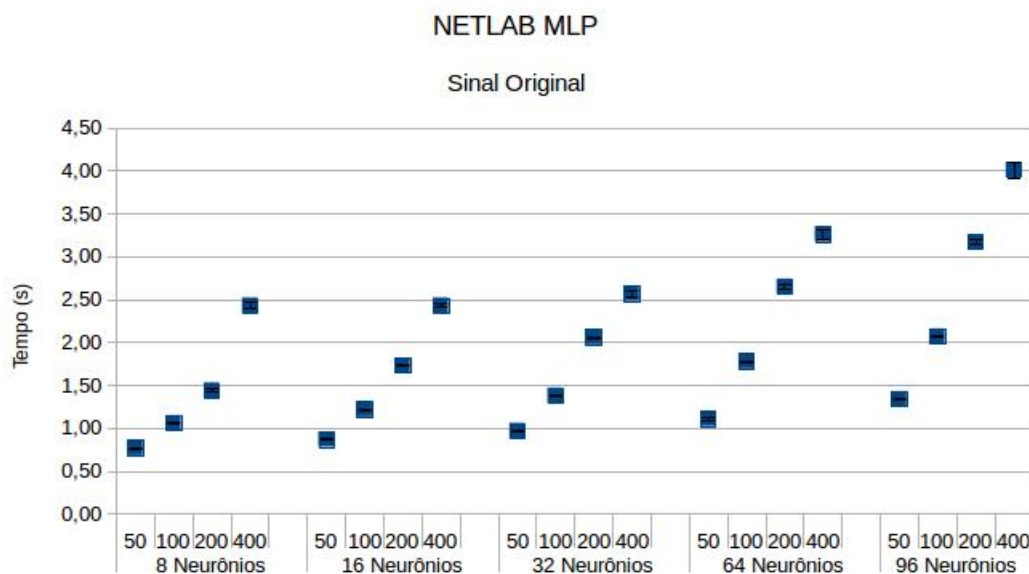


Figura 25: O tempo de treinamento diminui quando a complexidade do sistema é menor, em contrapartida os resultados seguem a tendência inversa.

O tempo não segue uma relação linear com o número de iterações, dobrar o número de ciclos não significa necessariamente dobrar o tempo de treino. A respeito do desvio padrão, o comportamento observado é o seguinte: o desvio padrão aumenta a medida que o número de iterações aumenta.

De maneira geral o algoritmo MLP quando alimentado pelo sinal re-amostrado, foi capaz de reconhecer os movimentos com quase a mesma precisão que quando alimentado pelo sinal original (diferença menor que 1% em todos os casos). Os

tempos ficaram praticamente idênticos em ambos os casos. Para verificar se existe uma diferença estatística entre as duas amostras, o teste pareado t foi aplicado em cada caso (tempo e acurácia). O objetivo do teste é verificar se após a generalização dos pontos, o classificador consegue obter os mesmos resultados para predição dos movimentos e seus respectivos tempos.

A figura 26 apresenta o resultado do teste para acurácia. De acordo com o teste houve uma diferença entre os resultados, sendo assim, o classificador não foi capaz de reconhecer os movimentos com a mesma acurácia em ambas as situações. Para confirmar o resultado basta verificar que o valor de P ($T \leq t$) bicaudal ficou menor do que o valor da significância ($0,000045312 < 0.05$).

| Teste T Pareado MLP | | | |
|----------------------------|-----------------|------------------------------------|--------------------------|
| Acurácia | | | |
| Re-amostrado | Original | | |
| 91,50 | 92,01 | Teste-t | |
| 93,89 | 94,27 | Alfa | 0,05 |
| 94,04 | 94,70 | Diferença média hipotética | 0 |
| 93,65 | 94,53 | Variável 1 | Variável 2 |
| 94,36 | 94,59 | Média | 95,246 95,5735 |
| 95,48 | 94,88 | Variância | 1,7065305263 1,492055526 |
| 95,77 | 96,09 | Observações | 20 20 |
| 95,76 | 96,23 | Correlação de Pearson | 0,9778977558 |
| 94,81 | 95,20 | Diferença média observada | -0,3275 |
| 95,84 | 96,33 | Variância das diferenças | 0,0777355263 |
| 96,47 | 96,72 | df | 19 |
| 96,58 | 96,83 | Estatística t | -5,2531104291 |
| 94,71 | 95,08 | P ($T \leq t$) unicaudal | 0,000022656 |
| 95,80 | 96,16 | t Crítico unicaudal | 1,7291328115 |
| 96,51 | 96,68 | P ($T \leq t$) bicaudal | 0,000045312 |
| 96,55 | 96,90 | t Crítico bicaudal | 2,0930240544 |
| 94,74 | 95,14 | | |
| 95,46 | 95,75 | | |
| 96,42 | 96,51 | | |
| 96,58 | 96,87 | Houve Diferença Estatística | |
| Teste T Pareado MLP | | | |

Figura 26: Resultado do teste t pareado aplicado as duas amostras (sinal original e re-amostrado) de resultados da rede Netlab MLP, com relação a acurácia.

A figura 27 traz o resultado do teste para o tempo. De acordo com o teste não houve uma diferença entre os resultados, sendo assim, o classificador levou o mesmo tempo em ambas as situações. Para confirmar o resultado basta verificar

que o valor de $P(T \leq t)$ bicaudal ficou maior do que o valor da significância ($0.64 > 0.05$).

| Teste T Pareado MLP | | | | |
|--|----------|----------------------------|---------------------|-------------|
| Tempo | | | | |
| Re-amostrado | Original | | | |
| 0,77 | 0,81 | Teste-t | | |
| 1,06 | 1,06 | Alfa | | 0,05 |
| 1,44 | 1,63 | Diferença média hipotética | | 0 |
| 2,43 | 2,46 | | Variável 1 | Variável 2 |
| 0,87 | 0,86 | Média | 1,916 | 1,905 |
| 1,22 | 1,20 | Variância | 0,8089936842 | 0,697826316 |
| 1,73 | 1,81 | Observações | 20 | 20 |
| 2,43 | 2,32 | Correlação de Pearson | 0,9955743418 | |
| 0,97 | 0,99 | Diferença média observada | 0,011 | |
| 1,38 | 1,39 | Variância das diferenças | 0,0107568421 | |
| 2,06 | 2,17 | df | 19 | |
| 2,57 | 2,59 | Estatística t | 0,4743132819 | |
| 1,11 | 1,14 | P (T<=t) unicaudal | 0,3203410501 | |
| 1,78 | 1,80 | t Crítico unicaudal | 1,7291328115 | |
| 2,65 | 2,61 | P (T<=t) bicaudal | 0,6406821002 | |
| 3,26 | 3,10 | t Crítico bicaudal | 2,0930240544 | |
| 1,34 | 1,33 | | | |
| 2,07 | 2,01 | | | |
| 3,17 | 3,13 | | | |
| 4,01 | 3,69 | | | |
| Não Houve Diferença Estatística | | | | |

Figura 27: Resultado do teste t pareado aplicado as duas amostras (sinal original e re-amostrado) da rede Netlab MLP, com relação ao tempo.

Embora no primeiro teste tenha ocorrido uma diferença entre os resultados, a diferença foi de apenas 0,88% no pior caso. Pode-se dizer que quando o volume de dados com o qual a prótese trabalha se tornar um fator limitante para o desenvolvimento do circuito, a técnica de re-amostragem do sinal pode ser testada.

6.2 Netlab GLM - scg

O estudo (ORTIZ-CATALAN et al., 2016) obteve uma precisão de $(97,4\% \pm 3,4\%)$ com tempo de 1,07 segundos. Considerando a mesma configuração da rede (todos os conjuntos de características e 200 iterações), o presente trabalho obteve uma precisão de $(94,58\% \pm 0,30\%)$ com tempo de 1,22 segundos. A tabela 3 mostra os

Tabela 3: Netlab GLM - SCG

| | Iterações | Acurácia(%) | DP | Tempo(s) | DP |
|----------------------------------|-----------|-------------|------|----------|-------|
| Duas Características | 25 | 85.94 | 0.56 | 0.22 | 0.002 |
| | 50 | 90.90 | 0.19 | 0.31 | 0.003 |
| | 100 | 92.73 | 0.36 | 0.49 | 0.005 |
| | 200 | 93.55 | 0.24 | 0.83 | 0.020 |
| Cinco Características | 25 | 90.06 | 0.37 | 0.30 | 0.004 |
| | 50 | 92.46 | 0.18 | 0.39 | 0.005 |
| | 100 | 93.22 | 0.18 | 0.57 | 0.010 |
| | 200 | 93.93 | 0.25 | 0.89 | 0.010 |
| Todas Características | 25 | 92.31 | 0.26 | 0.61 | 0.010 |
| | 50 | 94.35 | 0.21 | 0.68 | 0.004 |
| | 100 | 94.69 | 0.24 | 0.87 | 0.007 |
| | 200 | 94.58 | 0.30 | 1.15 | 0.02 |

resultados com os cenários onde o classificador foi testado.

Em geral, a rede Netlab GLM (scg) segue o mesmo comportamento do classificador não-linear Netlab MLP, a qualidade dos resultados é proporcional ao número de iterações. Por se tratar de um modelo linear não possui neurônios em sua arquitetura. Além disso, a rede é sensível à quantidade de informação que chega através dos conjuntos de características.

O gráfico da figura 28 mostra os resultados da acurácia para esta bateria de testes. Embora o classificador obtenha os melhores resultados quando alimentado por todas as características, a diferença de precisão na predição dos movimentos é pequena quando comparada à situação onde o classificador é alimentado apenas pelas cinco características mais relevantes.

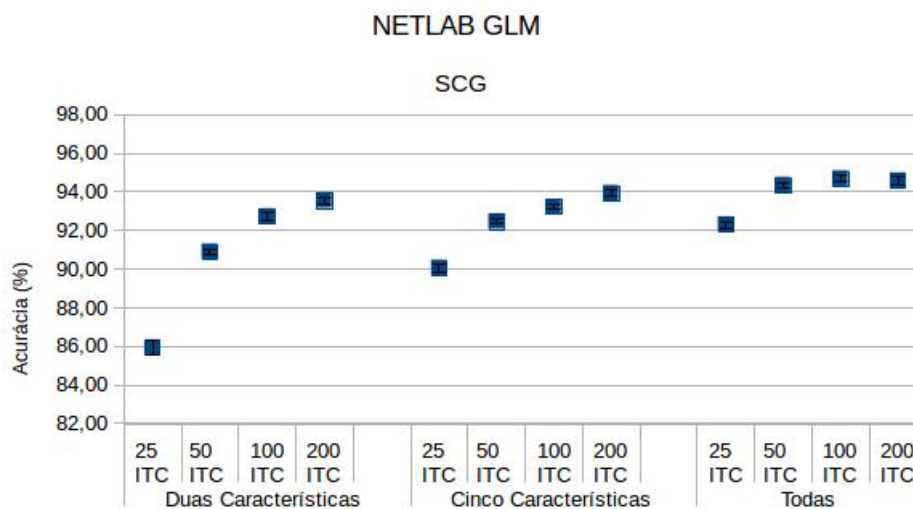


Figura 28: Variação da precisão para diferentes configurações. A diferença entre os resultados da rede quando alimentada por 5 conjuntos de características é inferior a 2%, em comparação ao algoritmo alimentado por todos os conjuntos.

O tempo aumenta à medida que o número de ciclos e conjuntos de características do sinal aumenta, isso pode ser verificado na figura 29. O tempo varia mais do que a acurácia em ambos os cenários, ou seja, se variarmos o número de iterações ou os conjuntos de características, o incremento no tempo de treino será maior que na predição dos movimentos.




Figura 29: Relação de tempo de treino para os diversos arranjos da rede.

6.3 Netlab GLM - irls

O último método otimizado avaliado foi o que obteve a menor acurácia na predição dos movimentos, em contra partida obteve os melhores tempos de treino dentre os classificadores vistos até aqui. O presente estudo obteve em seu melhor caso uma acurácia de $(94.02\% \pm 0.17\%)$ e um tempo de $(0.58\% \pm 0.014\%)$. A tabela 4 resume os resultados para esse classificador.

Tabela 4: Netlab GLM - IRLS

| | Iterações | Acurácia(%) | DP | Tempo(s) | DP |
|----------------------------------|-----------|-------------|------|----------|-------|
| Duas Características | 25 | 90.43 | 0.42 | 0.15 | 0.005 |
| | 50 | 90.50 | 0.25 | 0.16 | 0.004 |
| | 100 | 90.56 | 0.28 | 0.16 | 0.004 |
| | 200 | 90.37 | 0.37 | 0.15 | 0.004 |
| Cinco Características | 25 | 92.68 | 0.18 | 0.25 | 0.005 |
| | 50 | 92.65 | 0.26 | 0.25 | 0.004 |
| | 100 | 92.63 | 0.22 | 0.25 | 0.006 |
| | 200 | 92.87 | 0.21 | 0.25 | 0.006 |
| Todas Características | 25 | 94.02 | 0.17 | 0.58 | 0.014 |
| | 50 | 93.90 | 0.33 | 0.58 | 0.007 |
| | 100 | 94.01 | 0.25 | 0.60 | 0.011 |
| | 200 | 93.91 | 0.26 | 0.61 | 0.005 |

A figura 30 mostra que o algoritmo é sensível ao número de características que chegam até ele e apresenta uma pequena melhoria quando aumentamos a quantidade de informações disponíveis para a rede. No entanto, o classificador não apresenta nenhuma diferença estatística ($p < 0.05$) quando o número de iterações é aumentado, o que sugere que esse modelo otimizado funciona bem com pequenos ciclos. Assim como a predição dos resultados não apresentou variação significativa quando a métrica avaliada foi o número de iterações, o mesmo aconteceu em relação ao tempo de treinamento. O classificador não mostra qualquer melhoria quando as iterações variaram entre 25 e 200, porém, o tempo melhora à medida que os conjuntos de características do sinal diminui. A figura 31 ilustra essa relação.




Figura 30: A precisão não sofre variação nos resultados quando o número de iterações varia. O único fator relevante para este método de treinamento otimizado é o conjunto de características que alimentam o algoritmo.




Figura 31: Tal como com a precisão, o tempo não mostrou variações significativas em relação ao número de iterações. Isso sugere que a rede funciona bem com um número reduzido de ciclos.

6.4 LDA

O algoritmo LDA é um dos mais utilizados e estudados quando se trata de reconhecimento de padrões de sinais mioelétricos. Para este estudo, ele foi escolhido devido a sua velocidade e como critério de comparação em relação aos outros dois métodos lineares disponíveis no BioPatRec. O estudo (ORTIZ-CATALAN et al., 2016) obteve uma precisão de $(93,8\% \pm 7,2\%)$ com um tempo médio de 0,35 segundos, usando o conjunto de dados original e um protocolo de teste semelhante ao presente trabalho. No melhor caso neste trabalho, o classificador obteve $(95,46\% \pm 0,32\%)$ com um tempo médio de 0,23 segundos. A tabela 5 mostra os resultados.

Tabela 5: LDA

| | Acurácia(%) | DP | Tempo(s) | DP |
|---------------------------------|-------------|------|----------|-------|
| Duas Características | 95.21 | 0.2 | 0.16 | 0.003 |
| Cinco Características | 95.46 | 0.32 | 0.23 | 0.005 |
| Todas as Características | 93.28 | 0.32 | 0.51 | 0.01 |

O tempo de treinamento aumentou quando o conjunto de características aumentou, mas o mesmo não ocorreu com a precisão. O classificador apresentou melhores resultados de previsão quando alimentado por apenas dois ou cinco conjuntos, em vez de todos. Recordando que os conjuntos de características escolhidos foram aqueles que apresentaram os melhores resultados individualmente.

7 Análise Comparativa

7.1 Netlab MLP

O primeiro classificador é aquele que apresentou os melhores resultados em relação à precisão na predição dos movimentos. Como os resultados entre ambos os sinais (original e re-amostrado) ficaram muito próximos (diferença menor que 0.89% em todos os casos), pode-se dizer que em uma implementação real é possível realizar a re-amostragem do sinal, a fim de reduzir a quantidade de dados que chegam até a prótese, pois um sistema de reabilitação deve possuir baixa complexidade computacional e um baixo consumo de *hardware* (FARINA et al., 2014), porém os resultados diferem estatisticamente um do outro e o projetista deve ter isso em mente antes de planejar o experimento. Excluindo-se os casos de testes onde o número de neurônios foram 8, pode-se dizer que a variação entre as acurácias medidas é pequena quando o critério de avaliação é o número de neurônios, por exemplo, fixando-se o número de iterações em 100 e comparando a precisão entre as configurações de 16 e 32 neurônios, observou-se no primeiro caso um resultado de 95,88% e no segundo 96,33%.

Já o número de iterações que a rede pode realizar apresenta uma contribuição ligeiramente maior quando a medida de interesse é a acurácia. Quando a métrica de interesse é o tempo, ambas as variáveis interferem significativamente nos resultados, por exemplo, fixando-se o número de unidades escondidas em 32 e observando-se a variação dos resultados com relação a 50 e 100 iterações, verifica-se que a acurácia foi de 95,20% para 96,33% (aproximadamente 1%), porém o tempo

aumentou 40%. Um comportamento análogo foi observado para as demais amostras. Também foi possível constatar que para esse tipo de aplicação, a rede MLP apresentou uma saturação nos resultados quando configurada com 64 e 96 neurônios. Quando o tempo for o requisito de desempenho mais importante pode-se utilizar entre 16 e 32 neurônios, sem muito prejuízo para a acurácia.

7.2 Netlab GLM - scg

Em geral, o modelo linear Netlab GLM (scg) apresentou resultados inferiores à rede MLP (em torno de 2%), neste caso, é difícil fazer uma comparação mais rigorosa devido às diferenças de arquitetura de ambas as redes. O classificador é sensível ao número de conjuntos que chegam a ele e apresentou bons resultados quando alimentados por 5 ou todos os conjuntos, sem grande diferença quando a métrica testada é a precisão na predição.

Em relação ao tempo, o classificador apresentou melhores resultados do que a rede MLP e demorou mais que 1 segundo para treinar a rede em apenas um caso de teste (200 iterações com todas as características), outro fator observado é que o tempo de treino é mais sensível a variações no número de iterações, em detrimento dos conjuntos de características que alimentam o classificador. Para o caso em que a rede foi alimentada com apenas dois conjuntos, pode-se afirmar que os resultados foram ruins em relação à predição dos movimentos.

7.3 Netlab GLM - irls

O algoritmo otimizado não mostrou diferença nos resultados quando o fator avaliado foi o número de iterações. Em relação à precisão, os resultados ficaram abaixo (94,58% contra 93,91%, no melhor caso de ambos) da rede GLM (scg). Quando os conjuntos de características foram avaliados, a predição dos resultados variou menos de 2% entre um cenário e outro, já o tempo variou cerca de 60% entre

os testes com dois e cinco conjuntos e aumentou 100% quando todos os conjuntos de características foram escolhidos, ao invés de cinco. Em geral o algoritmo foi o mais rápido da família Netlab (atingindo 0,6 segundos no pior caso e 0,15 segundos no melhor caso, contra 1,15 segundos e 0,22 segundos respectivamente), porém apresentou uma acurácia relativa ao Netlab GLM (scg) baixa. O classificador não é sensível a variações no número de iterações.

7.4 LDA

O modelo LDA clássico apresentou resultados diferentes com relação aos outros algoritmos, ao contrário dos outros modelos lineares, a precisão diminuiu quando o classificador foi alimentado por todos os conjuntos de treinamento. Quando os testes foram feitos com dois e cinco grupos, apresentou 95,21% e 95,46% de precisão no reconhecimento dos padrões, em ambos os casos os resultados foram melhores que os demais modelos lineares testados. Além disso, o tempo de treinamento foi de 0,16 segundos para o primeiro caso e 0,23 para o segundo, os melhores resultados do estudo. Comparando com o melhor caso da rede MLP (96.87%) onde o tempo foi 4,01 segundos, o algoritmo LDA foi 17 vezes mais rápido, com uma diferença inferior a 2% na qualidade da previsão.

Quando comparado com o classificador GLM (scg), a rede LDA é mais rápida em todos os casos, dado o conjunto de característica escolhido para essa comparação. A rede GLM (irls) conseguiu executar com 0,15 segundos em um dos casos, mas com quase 5% menos precisão que o modelo linear discriminante. O primeiro resultado da LDA foi capaz de cumprir um dos requisitos de desempenho para o desenvolvimento de uma prótese, que é treinar e reconhecer os padrões do sinal mioelétrico com menos de 0,2 segundos (FARRELL; WEIR, 2007a), isso é desejável para que o indivíduo não abandone o artefato.

7.5 Estudo sobre a População

Durante a realização do experimento observou-se que a capacidade de reconhecimento de padrões dos algoritmos de classificação descritos nesse trabalho, também é produto do indivíduo o qual esta sendo analisado. A figura 32 mostra o resultado da acurácia média entre a população analisada para o classificador Netlab GLM-scg.




Figura 32: Acurácia média por indivíduo. Rede GLM-scg alimentada por todas as características com 200 iterações.

Percebe-se que há uma discrepância nos valores observados, o que sugere que a capacidade de reconhecimento de tal máquina está alinhada a fatores intrínsecos (esforço, fadiga, posicionamento do eletrodo) ao indivíduo. Através da figura 33 é possível observar que a qualidade no reconhecimento, relativa a população, permanece a mesma quando analisada por outro algoritmo (MLP).




Figura 33: Acurácia média por indivíduo. Rede MLP com 32 neurônios realizando 200 iterações.

É possível observar que tanto para rede GLM e MLP os indivíduos 3, 5, 13 e 18 apresentaram resultados relativamente baixos, em comparação com 1, 2, 6 e 17 respectivamente.

8 Conclusão

A dissertação estudou e avaliou algumas técnicas comumente utilizadas para reconhecimento de padrões do sinal mioelétrico, apresentou uma tabela de operação para cada um dos classificadores e discutiu os resultados conforme os principais desafios da área.

Assim como outros trabalhos, o classificador MLP foi o que apresentou os melhores resultados com relação a acurácia no reconhecimento dos padrões de movimento, apresentando diferenças estatísticas com relação aos demais. Apesar do tempo relativo de treino não ter sido o melhor dentre as soluções apresentadas, esse algoritmo ainda representa o estado da arte para esse tipo de problema de classificação. Outro critério avaliado foi a possibilidade de realizar uma generalização dos pontos do sinal mioelétrico, através da re-amostragem do sinal. Após a comparação estatística com auxílio do teste t , verificou-se que havia diferença nos resultados da acurácia, o tempo não apresentou variação, segundo os mesmo critério.

O classificador Netlab GLM *scg* apresentou resultados inferiores em comparação a rede Netlab MLP (94,69% contra 96,87%, no melhor caso de ambos). Com relação ao tempo, o algoritmo foi mais rápido em todos os casos, comparando-se com os resultados obtidos pela rede MLP. O algoritmo Netlab GLM com método otimizado de treino *irls* foi o que apresentou os resultados mais inferiores (93,91% no melhor caso) em relação a predição dos movimentos e com o melhor tempo de treino (0,15 segundos) dentre todas as abordagens testadas.

O algoritmo LDA, foi avaliado a respeito dos conjuntos de características que

alimentam o mesmo e diferente dos demais classificadores ele funcionou melhor quando alimentado por duas ou cinco características, ao invés de todas. Fazendo uma comparação com os outros dois métodos lineares, o LDA apresentou a melhor acurácia na predição dos movimentos, a respeito do tempo ele foi mais lento apenas com relação a rede Netlab GLM *irls*. Comparando-se com a rede MLP os resultados ficaram muito próximos e divergiram em menos de 2% na maioria dos casos, porém com um tempo de treino até 17 vezes mais rápido (comparação entre o melhor caso de ambos, com relação a acurácia).

Também é possível concluir que a qualidade no reconhecimento de padrões está relacionada as características individuais de cada sinal, ou seja, existe uma variabilidade entre uma pessoa e outra. Questões como fadiga ou esforço do usuário acabam interferindo no resultado final da classificação.

9 Trabalhos Futuros

Futuramente pretende-se desenvolver um circuito eletrônico baseado em linguagem descritiva de *hardware* (VHDL ou Verilog) capaz de executar os mesmos algoritmos de reconhecimento de padrões disponíveis na plataforma BioPatRec, com a finalidade de embarcá-lo em um protótipo de uma prótese. Como a plataforma mencionada é de código aberto e totalmente modular os classificadores que apresentaram o melhor desempenho no trabalho de mestrado serão usados para a construção de tal sistema.

Um sistemas dedicado de *hardware* é capaz de executar uma determinada tarefa mais rápido do que o seu equivalente em *software* (BOSCHMANN et al., 2017). Um dos requisitos de desempenho para construção de uma prótese exige que o sinal mioelétrico seja decodificado em menos de 200 milissegundos (FARINA et al., 2014) e (SMITH et al., 2011), o que nem sempre acontece com os classificadores implementados em *software*, além do mais não é apenas a classificação que deve ocorrer nessa janela de tempo, o sinal deve ser devidamente filtrado e deve haver uma extração de características do mesmo, antes de alimentar os algoritmos de reconhecimento. Com essa prerrogativa é razoável afirmar que um circuito construído com os mesmos algoritmos de filtragem, extração de características e classificação seria capaz de atender os critérios de desempenho.

Além do tempo, a acurácia é outro fator limitante para a construção de tal sistema, nesse ponto o circuito construído seria incapaz de melhorar os resultados, pois tecnicamente implementa as mesmas funções que o BioPatRec, porém em um nível mais baixo de abstração. Para mitigar tal demanda pode-se utilizar

um modelo de validação por referência cruzada onde o sinal captado alimentaria dois classificadores lineares diferentes (LDA e Netlab GLM) e havendo divergência entre os resultados (pronação ou supinação do extensor carpis) uma rede mais complexa como a MLP daria o resultado final.

Referências

- AMSUSS, S. et al. Long term stability of surface emg pattern classification for prosthetic control. 35th Annual International Conference of Engineering in Medicine and Biology Society, Osaka, Japan, 2013.
- BORGES, A. *Diferença entre placa motora e junção neuromuscular*. 4 2014. <https://questoesdefisiocomentadas.wordpress.com/tag/diferenca-entre-placa-motora-e-juncao-neuromuscular/>.
- BOSCHMANN, A. et al. Iir digital filter design implemented on fpga for myoelectric signals. International Conference on ReConFigurable Computing and FPGAs, Santiago de Queretaro, Mexico, 2017.
- CARRIZOSA, E.; M.BARRAGÃN, B.; MORALES, D. R. Detecting relevant variables and interactions in supervised classification. European Journal of Operational Research, Elsevier - Amsterdam, 2011.
- COMPRIMENTO de Onda. nov. 2017. Disponível em: <<http://www2.eca.usp.br/prof/iazzetta/tutor/acustica/comprimento/comprim.html>>.
- DAVIDSON, J. A survey of the satisfaction of upper limb amputees with their prostheses, their lifestyles, their abilities. The Journal of Hand Therapy, Elsevier - Amsterdam, 2002.
- ENGLEHART, K. et al. Classification of the myoelectric signal using time-frequency based representations. Medical Engineering and Physics, Elsevier - Amsterdam, 1999.
- ENGLEHART, K. B.; HUDGINS, B. S. A robust, real-time control scheme for multifunction myoelectric control. IEEE Transactions on Biomedical Engineering, University of Minnesota - Minneapolis, MN 55455 USA, 2013.
- FARINA, D. et al. Decoding the neural drive to muscles from the surface electromyogram. Clinical Neurophysiology, Elsevier - Amsterdam, 2010.
- FARINA, D. et al. The extraction of neural information from the surface emg for the control of upper-limb prostheses: Emerging avenues and challenges.

IEEE Transactions on Neural Systems and Rehabilitation Engineering, 1210 Amsterdam Avenue - New York, NY 10027 USA, 2014.

FARRELL, T. R.; WEIR, R. F. The optimal controller delay for myoelectric prostheses. IEEE Transactions on Neural Systems and Rehabilitation Engineering, Columbia University - New York - USA, 2007.

FARRELL, T. R.; WEIR, R. F. The optimal controller delay for myoelectric prostheses. IEEE Transactions on Neural Systems and Rehabilitation Engineering, Columbia University - New York - USA, 2007.

FISHER, R. A. The use of multiple measurements in taxonomic problems. Annals of Eugenics, University College London, 1936.

FOUGNER, A. et al. Resolving the limb position effect in myoelectric pattern recognition. IEEE Transactions on Neural Systems and Rehabilitation Engineering, Columbia University - New York - USA, 2011.

FOUGNER, A. et al. Control of upper limb prostheses: Terminology and proportional myoelectric control - a review. IEEE Transactions on Neural Systems and Rehabilitation Engineering, Columbia University - New York - USA, 2012.

GUANGLIN, L. et al. Conditioning and sampling issues of emg signals in motion recognition of multifunctional myoelectric prostheses. Annals of Biomedical Engineering, Spring St. - New York, 2011.

HARGROVE, L.; ENGLEHART, K.; HUDGINS, B. A training strategy to reduce classification degradation due to electrode displacements in pattern recognition based myoelectric control. Biomed. Signal Process, Elsevier - Amsterdam, 2008.

HENNEMAN, E. The size-principle: A deterministic output emerges from a set of probabilistic connec. Journal of Experimental Biology, Cambridge - UK, 1985.

HOWARD, R. M. *The application of data analysis methods for surface electromyography in shot putting and sprinting*. Dissertação (Mestrado) — University of Limerick, https://ulir.ul.ie/bitstream/handle/10344/5584/Howard2016_application.pdf?sequence=6, 1 2016.

HUDGINS, B.; HUDGINS, B.; SCOTT, R. The recognition of myoelectric patterns for prosthetic limb control. Engineering in Medicine and Biology Society, 1991. Vol.13: 1991., Proceedings of the Annual International Conference of the IEEE, Orlando, FL - USA, 1991.

HUDGINS, B.; PARKER, P.; N, S. R. A new strategy for multifunction myoelectric control. IEEE Transactions on Biomedical Engineering, University of Minnesota - Minneapolis - USA, 1993.

HUDGINS, B.; PARKER, P.; SCOTT, R. N. A neural network classifier for multifunction myoelectric control. Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Orlando, FL, USA, 1993.

ISHOLA, K. S.; NAWAWI, M. N. M.; ABDULLAH, K. Combining multiple electrode arrays for two-dimensional electrical resistivity imaging using the unsupervised classification technique. Pure and Applied Geophysics, Springer International Publishing, 2014.

JIANG, N. et al. Myoelectric control of artificial limbs - is there a need to change focus? [in the spotlight]. IEEE Signal Processing Magazine, University of Maryland, College Park - USA, 2012.

JIANG, N. et al. Determining the optimal window length for pattern recognition-based myoelectric control: Balancing the competing effects of classification error and controller delay. Journal of NeuroEngineering and Rehabilitation, BioMed Central - London, 2012.

KUIKEN, T. Targeted reinnervation for improved prosthetic function. Physical Medicine and Rehabilitation Clinics of North America, Maryland Heights, MO 63043 - USA, 2016.

LINEAR Discriminant Analysis. jan. 2018. Disponível em: <https://sebastianraschka.com/Articles/2014_python_lda.html>.

LUCA, C. J. de et al. Behaviour of human motor units in different muscles during linearly varying contractions. The Journal of Physiology, Malden MA - USA, 1982.

MERLETTI, R.; KNAFLITZ, M. Electrically evoked myoelectric signals. Critical Reviews in Biomedical Engineering, Boston, MA, 1992.

MIX, B. C. *Perceptron Multicamadas*. 1 2010. *http* : [//www.culturamix.com/tecnologia/inteligencia-artificial/perceptron-multicamadas/](http://www.culturamix.com/tecnologia/inteligencia-artificial/perceptron-multicamadas/).

MODELOS Lineares Generalizados. nov. 2017. Disponível em: <<https://docs.ufpr.br/~taconeli/CE225/tp.pdf>>.

- MORAIS, E. C. *Reconhecimento de Padrões e Redes Neurais Artificiais em Predição de Estruturas Secundárias de Proteínas*. Dissertação (Mestrado) — COPPE/UFRJ, <http://www.cos.ufrj.br/uploadfile/1277729485.pdf>, 3 2010.
- MÚSCULOS: como nos movimentamos? nov. 2017. Disponível em: <<http://www.museuescola.ibb.unesp.br/subtopico.php?id=2&pag=2&num=3>>.
- NELDER, J. A.; BAKER, R. J. *Generalized Linear Models: Generalized linear models*. [S.l.]: Encyclopedia of Statistical Sciences, 2006.
- NYQUIST, H. Certain topics in telegraph transmission theory. Trans. AIEE, University of Texas at Dallas Richardson, TX, USA, 1928.
- ORTIZ-CATALAN, M. Cardinality as a highly descriptive feature in myoelectric pattern recognition for decoding motor volition. *Frontiers in Neuroscience*, Lausanne - Switzerland, 2015.
- ORTIZ-CATALAN, M. *Github BioPatRec*. 10 2017. <https://github.com/biopatrec/biopatrec/wiki>.
- ORTIZ-CATALAN, M.; BRANEMARK, R.; HAKANSSON, B. Biopatrec: A modular research platform for the control of artificial limbs based on pattern recognition algorithms. *Source Code for Biology and Medicine*, BioMed Central - London, 2013.
- ORTIZ-CATALAN, M.; HAKANSSON, B.; BRANEMARK, R. Real-time and simultaneous control of artificial limbs based on pattern recognition algorithms. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Columbia University - New York - USA, 2007.
- ORTIZ-CATALAN, M. et al. Combining two open source tools for neural computation (biopatrec and netlab) improves movement classification for prosthetic control. *BMC Res Notes*, BioMed Central - London, 2016.
- ORTOLAN, R. L. *Estudo E Avaliação de Técnicas de processamento do Sinal Mioelétrico para controle de sistemas de reabilitação*. Dissertação (Mestrado) — Universidade de São Paulo, <http://www.teses.usp.br/teses/disponiveis/18/18133/tde-19112002-153337/pt-br.php>, 4 2002.
- PAPAGELIS, A. J.; KIM, D. S. *Backpropagation*. 9 2017. <Http://www.cse.unsw.edu.au/cs9417ml/MLP2/>.
- PICCOLINO, M. Animal electricity and the birth of electrophysiology: the legacy of luigi galvani. *Brain Research Bulletin*, Elsevier - Amsterdam, 1998.

R.C., G.; M.G, T. Syntactic pattern recognition, an introduction. Addison-Wesley, Reading, Mass., 1978.

SANTOS, D. *Testes de Bioeletrogene*. 10 2015. *https* :
//djalmasantos.wordpress.com/2015/10/19/testes – de – bioeletrogenese – 23/.

SCHEME, E. J.; ENGLEHART, K. B.; HUDGINS, B. S. Selective classification for improved robustness of myoelectric control under nonideal conditions. IEEE Transactions on Biomedical Engineering, University of Minnesota - Minneapolis, MN 55455 USA, 2011.

SHANNON, C. E. Communication in the presence of noise. Proc. Institute of Radio Engineers, North Carolina State University - USA, 1949.

SMITH, L. H. et al. Emg-based simultaneous and proportional estimation of wrist/hand dynamics in uni-lateral trans-radial amputees. IEEE Transactions on Neural Systems and Rehabilitation Engineering, Columbia University - New York, NY 10027 USA, 2011.

VARELLA, C. A. A. *Análise Multivariada Aplicada As Ciências Agrárias*. 9 2017. *Http://www.ufrj.br/institutos/it/deng/varella/*.