

ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO EM ENGENHARIA ELÉTRICA

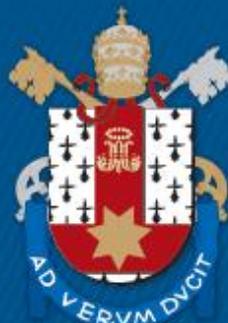
GRÉGORI STEFANELLO SPONCHIADO

**ESTRATÉGIA DE CARACTERIZAÇÃO DE SINAIS ELETROMIOGRÁFICOS BASEADA EM
REDES NEURAS ARTIFICIAIS PARA SISTEMAS DE CONTRLE DE MÁQUINAS DE
MOVIMENTO CONTÍNUO**

Porto Alegre

2019

PÓS-GRADUAÇÃO - *STRICTO SENSU*



Pontifícia Universidade Católica
do Rio Grande do Sul

GRÉGORI STEFANELLO SPONCHIADO

**ESTRATÉGIA DE CARACTERIZAÇÃO DE
SINAIS ELETROMIOGRÁFICOS BASEADA
EM REDES NEURAIS ARTIFICIAIS PARA
SISTEMAS DE CONTROLE DE MÁQUINAS
DE MOVIMENTO CONTÍNUO**

Porto Alegre - RS, Brasil

2019

GRÉGORI STEFANELLO SPONCHIADO

**ESTRATÉGIA DE CARACTERIZAÇÃO DE SINAIS
ELETROMIOGRÁFICOS BASEADA EM REDES
NEURAS ARTIFICIAIS PARA SISTEMAS DE
CONTROLE DE MÁQUINAS DE MOVIMENTO
CONTÍNUO**

Dissertação apresentada como requisito para a obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica da Escola Politécnica da Pontifícia Universidade Católica do Rio Grande do Sul.
Área de Concentração: Sinais Sistemas e Tecnologia da Informação.
Linha de Pesquisa: Engenharia Biomédica.

Pontifícia Universidade Católica do Rio Grande do Sul

Escola Politécnica

Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Fabian Luis Vargas

Porto Alegre - RS, Brasil

2019

Ficha Catalográfica

S816e Stefanello Sponchiado, Grégori

Estratégia de caracterização de sinais eletromiográficos baseada em redes neurais artificiais para sistemas de controle de máquinas de movimento contínuo / Grégori Stefanello Sponchiado . – 2019.

84p.

Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, PUCRS.

Orientador: Prof. Dr. Fabian Luis Vargas.

1. Aprendizado de máquina. 2. Redes neurais artificiais. 3. EMG. 4. CPM. 5. CAM. I. Vargas, Fabian Luis. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da PUCRS com os dados fornecidos pelo(a) autor(a).

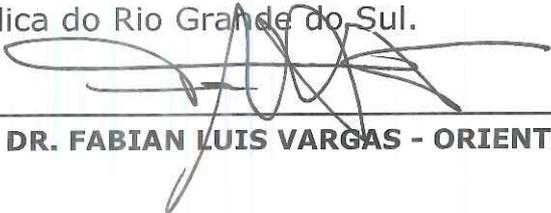
Bibliotecária responsável: Clarissa Jesinska Selbach CRB-10/2051



**ESTRATÉGIA DE CARACTERIZAÇÃO DE SINAIS
ELETROMIOGRÁFICOS BASEADA EM REDES NEURAIS
ARTIFICIAIS PARA SISTEMAS DE CONTROLE DE
MÁQUINAS DE MOVIMENTO CONTÍNUO**

CANDIDATO: GRÉGORI STEFANELLO SPONCHIADO

Esta Dissertação de Mestrado foi julgada para obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica do Rio Grande do Sul.

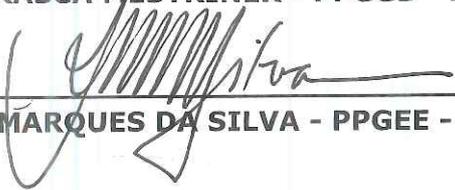


DR. FABIAN LUIS VARGAS - ORIENTADOR

BANCA EXAMINADORA



DR. RÉGIS GEMERASCA MESTRINER - PPGGB - PUCRS



DRA. ANA MARIA MARQUES DA SILVA - PPGE - PUCRS

Aos meus avós, Aléssio e Leonida, e a minha mãe Sandra dedico este trabalho.

Agradecimentos...

Aos meus avós, Aléssio e Leonida, e minha mãe Sandra e toda minha família, deixo um agradecimento muito especial, pois sempre me apoiaram, me ajudaram e tiveram um papel especial e fundamental. Certamente sem eles não teria sido possível a realização deste trabalho.

Obrigado ao meu orientador Fabian Luis Vargas, por me orientar nos últimos momentos, e dar sentido, foco e objetivo ao meu trabalho.

Muito obrigado Diego Cintrão, pois sempre me ajudou e comemorou a cada passo dado em direção a conclusão deste trabalho.

Agradeço também ao professor Júlio César Marques de Lima, por sempre estar presente e ajudar mesmo quando não tinha obrigação, és um exemplo de profissional e pessoal, uma inspiração.

Por último, mas não menos importante, agradeço a minha namorada Ana Paula por estar sempre ao meu lado disposta a ajudar e me dar força nos momentos mais difíceis. Obrigado pelas palavras e orações. Obrigado por saber escutar e ter muita paciência.

"No fim tudo dá certo... se não deu certo, é porque ainda não chegou no fim"

(Fernando Sabino)

Resumo

Os seres humanos sofrem frequentemente de lesões nos membros inferiores, principalmente as relacionadas aos movimentos diários, sendo o envelhecimento um fator de risco. Isso afeta a saúde e submete o corpo humano a intervenções cirúrgicas e terapias indesejáveis. Nesse cenário, os objetivos deste trabalho são: (a) usar rede neural artificial (RNA) para identificar e classificar padrões musculares com base em sinais eletromiográficos (EMG) e (b) usar a decisão de saída da RNA para controlar uma Máquina Movimento Passivo (CPM, do termo em inglês: *Continuous Passive Movement*) durante uma sessão de fisioterapia do paciente. A estratégia usa eletromiografia de superfície combinada com um método de aprendizado supervisionado e inteligência artificial (IA) para criar um sinal de *feedback* que permite que esses dispositivos funcionem no modo de Movimento Ativo Contínuo (CAM, do termo em inglês: *Continuous Active Movement*). Métodos: Este trabalho utilizou 300 sinais EMG coletados do músculo vasto lateral de 10 indivíduos saudáveis para desenvolver um sistema classificador de força. O núcleo do classificador é composto por uma rede neural treinada (*backpropagation*). Os sinais EMG são classificados em níveis de força pré-definidos, que por sua vez são usados como entradas para controlar uma máquina de CPM. Assim, existe uma correspondência direta entre cada um dos níveis de força pré-definidos e o deslocamento linear da máquina CPM. Resultados: A RNA treinada classifica, em tempo real, sinais EMG em níveis de força com precisão de 81% com eficiência computacional. Após receber os níveis de força pré-definidos da saída da RNA, o atraso que o sistema de controle mecânico leva para ajustar a máquina de CPM é inferior a 100 segundos. Conclusão: A assertividade baseada em IA da estratégia proposta nos permite considerar a extensão do uso de sinais EMG de músculo único para pavimentar o caminho para o controle de outras máquinas biomecânicas em um futuro próximo.

Palavras-chaves: Aprendizado de máquina, Redes neurais artificiais, EMG, CPM, CAM

Abstract

Human beings often suffer from lower limb injuries which are mostly related to aging and daily-motion. This impacts health and exposes human body to undesirable surgical interventions and therapies. In this scenario, the goal of this work is twofold: (a) use artificial neural network (ANN) to identify and classify muscle usage patterns based on electromyographic (EMG) signals, and (b) use the ANN's output decision to control a Continuous Passive Motion (CPM) machine during a patient physiotherapy session. The strategy uses surface electromyography (sEMG) combined with a supervised learning method and artificial intelligence (AI) to create a feedback signal which allows these devices to function in Continuous Active Motion (CAM) mode. Methods: This work used 300 EMG signals collected from the vastus lateralis muscle of 10 healthy individuals to develop a strength classifier system. The core's classifier is composed of a trained (backpropagation) feedforward neural network. The EMG signals are classified into predefined force levels, which in turn are used as inputs to control a CPM machine. Thus, there is a direct correspondence between each of the predefined force levels and the CPM machine linear displacement. Results: The trained ANN classifies, at real-time, EMG signals into force levels at 81 % accuracy with computational efficiency. After receiving the predefined force levels from the ANN's output, the delay of the mechanical control system to adjust the CPM machine is less than 100 seconds. Conclusion: The AI-based assertiveness of the proposed strategy allows us to consider extending the use of single muscle EMG signals to pave the way for controlling another biomechanical machines in a near future.

Key-words: Machine learning, Artificial neural networks, EMG, CPM, CAM

Lista de ilustrações

Figura 1 – Dispositivo CPM/CAM de Ho e Chen	26
Figura 2 – Dispositivo CPM para tornozelos	27
Figura 3 – Máquina para reabilitação manual de Amrani	28
Figura 4 – Dispositivos para membros superiores	29
Figura 5 – Máquina de CPM comercial	32
Figura 6 – Máquina de CAM comercial	33
Figura 7 – Ciclo de despolarização e repolarização da membrana muscular	35
Figura 8 – Processo simplificado de aquisição e caracterização de um EMG	36
Figura 9 – Técnicas do <i>Machine Learning</i> mais utilizados na classificação de EMGs	38
Figura 10 – Modelo de um neurônio artificial	40
Figura 11 – Rede neural com camadas ocultas	41
Figura 12 – Sistema de impedância mecânica-interação máquina de CPM/CAM- paciente	42
Figura 13 – Modelo de impedância de segunda ordem	43
Figura 14 – Malha de controle com <i>feedback</i> simples	45
Figura 15 – Exemplos do critério de Nyquist:	46
Figura 16 – Diagrama de blocos simplificado de um sistema de classificação de EMG	47
Figura 17 – Etapas da técnica proposta	49
Figura 18 – Fluxograma de Funcionamento da Técnica proposta	50
Figura 19 – Equipamento utilizado na coleta de dados(Flexora-Extensora)	52
Figura 20 – Posicionamento de eletrodos no músculo vasto lateral, segundo a lite- ratura	53
Figura 21 – Eletromiógrafo utilizado na coleta de dados	54
Figura 22 – Eletrodos de superfície autoadesivos	55
Figura 23 – Dinamômetro	55
Figura 24 – Sinal EMG "cru"vs filtrado e suavizado	56
Figura 25 – Processo de segmentação	57
Figura 26 – Localizações das janelas após segmentação	58
Figura 27 – Classificador de forças baseado em rede neural	59
Figura 28 – Sistema de Controle da Máquina de CPM	60
Figura 29 – Diagrama de blocos do sistema de controle	61
Figura 30 – Entropia Cruzada	64
Figura 31 – Matriz de confusão	65
Figura 32 – Saída do sistema em malha fechada	66

Figura 33 – Diagrama de Nyquist do sistema de controle em malha fechada 67
Figura 34 – Raízes do sistema de controle em malha fechada 67

Lista de tabelas

Tabela 1 – Comparação dos trabalhos relacionados com a técnica proposta	29
Tabela 2 – Dados demográficos do grupo	51
Tabela 3 – Energia media por contração vs níveis de força	63

Lista de abreviaturas e siglas

ANN	Rede neural artificial, do termo em inglês: <i>Artificial Neural Network</i>
BP	Retro-propagação, do termo em inglês: <i>Backpropagation</i>
CPM	Movimento passivo contínuo, do termo em inglês: <i>Continuous Passive Motion</i>
CAM	Movimento ativo contínuo, do termo em inglês: <i>Continuous Active Motion</i>
CZ	Cruzamento de zero
DF	Domínio de frequência
DT	Domínio de tempo
EMG	Eletromiografia
EMGs	Sinais eletromiográficos
FNN	Rede neural difusa, do termo em inglês: <i>Fuzzy Neural Network</i>
FM	Frequência média
FFT	Transformada rápida de Fourier, do termo em inglês: <i>Fast Fourier Transform</i>
HSL	Hospital São Lucas
IA	Inteligência artificial
MLT	Ferramentas do aprendizado de máquina, do termo em inglês: <i>Machine Learning Tools</i>
ML	Aprendizado de máquina, do termo em inglês: <i>Machine Learning</i>
mbk	Massa-mola-amortecedor
MLP	<i>Multilayer Perceptron</i>
OA	Osteoartrite
PID	Controlador Proporcional Integral e Derivativo, do termo em inglês: <i>Proportional Integral Derivative Controller</i>

PSD	Densidade do espectro de potência, do termo em inglês: <i>Power Spectral Density</i>
RNA	Rede neural artificial
RM	Repetição máxima
RNFFMC	Rede neural <i>feedforward</i> de múltiplas camadas
ROM	Amplitude de movimento, do termo em inglês: <i>Range of Movement</i>
SCG	Gradiente conjugado em escala, do termo em inglês: <i>Scaled Conjugate Gradient</i>
sEMG	Sinal eletromiográfico de superfície, do termo em inglês: <i>Surface Electromyography</i>
TCLE	Termo de consentimento livre e esclarecido
VAM	Valor absoluto médio
WL	Comprimento da forma de onda, do termo em inglês: <i>Waveform length</i>

Lista de símbolos

ζ	Coeficiente de amortecimento do sistema
ω_n	Frequência natural de oscilação do sistema
x	Deslocamento
K	Constante da mola
b	Coeficiente de atrito
M	Massa
P	Número de polos de malha aberta
N	Circunscrições da origem no diagrama de Nyquist
Z	Número de polos em malha fechada no semiplano s direito
Na_+	Íons de Sódio
K_+	Íons de Potássio
y_k	Sinais de saída
$W_{k,n}$	Pesos sinápticos
ϕ	Função de ativação
b_k	Bias
x_n	Sinais de entrada
v	Sinal da junção aditiva
θ	Constante arbitrária de ajuste do número neurônios
N_n	Número de neurônios da camada escondida
in	Número de neurônios da camada entrada
out	Número de neurônios da camada saída
G_p	Modelo de controle da planta ou processo
G_c	Modelo de controlador

e	Erro
r	Referência
y	Saída do sistema de controle
u	Lei de controle
$j\omega$	Frequência complexa
Im	Conjunto dos números imaginários
Re	Conjunto dos números reais
$csgn(\dot{x})$	Fricção não-linear de Coulomb
Ag-AgCl	Prata-cloreto de prata
s	Variável de Laplace
T	Função de Transferência em Malha Fechada
Q	Equação característica

Sumário

1	INTRODUÇÃO	21
2	OBJETIVOS	23
2.1	Objetivo geral	23
2.1.1	Objetivos específicos	23
2.2	Escopo do trabalho	23
3	ESTADO DA ARTE	25
4	FUNDAMENTAÇÃO TEÓRICA	31
4.1	Osteoartrite	31
4.2	Movimentação passiva contínua	31
4.3	Movimentação ativa contínua	33
4.4	Eletromiografia	34
4.4.1	Decomposição de um sinal eletromiográfico	35
4.5	Caracterização de sinais de EMG baseados em IA	37
4.5.1	Redes neurais artificiais	39
4.5.2	<i>Multilayer Perceptrons</i>	39
4.6	Sistema de Controle	41
4.6.1	Modelagem matemática de uma máquina de CPM/CAM	42
4.6.2	Crítério de estabilidade de Nyquist	44
4.7	Sistema genérico de identificação e controle baseado em EMG	47
5	A TÉCNICA PROPOSTA	49
5.1	Aquisição dos sinais eletromiográficos no voluntário	50
5.1.1	Desenho experimental	51
5.1.2	Exercício experimental	51
5.1.3	Teste de força máxima (1RM)	52
5.1.4	Posicionamento dos eletrodos para a coleta da eletromiografia	53
5.2	Filtragem e segmentação dos sinais eletromiográficos	56
5.2.1	Processos de filtragem	56
5.2.2	Segmentação	57
5.2.3	Caracterização do EMG	58
5.3	Classificador de força (rede neural artificial)	59
5.4	Sistema de controle	60
6	VALIDAÇÃO	63

7 AVALIAÇÃO	69
8 CONCLUSÕES FINAIS	71
9 TRABALHOS FUTUROS	73
Referências	75
APÊNDICE A	79
A.1 Termo de Consentimento Livre e Esclarecido	79
Anexos	81

1 INTRODUÇÃO

O homem sofre frequentemente com problemas de saúde relacionados a lesões que afetam músculos e articulações, principalmente em segmentos dos membros inferiores como joelhos e tornozelos, devido ao envelhecimento das estruturas ou ao desgaste natural que ocorre durante o processo de locomoção. Um dos problemas mais recorrentes é a osteoartrite, doença degenerativa que afeta cerca de 15% da população adulta no mundo e é a terceira maior causa de afastamento de pessoas por auxílio doença no Brasil. Em quadros mais agudos, as pessoas precisam passar por cirurgias para recuperar sua mobilidade. Um dos procedimentos cirúrgicos indicados é a Artroplastia, que é realizada em pacientes com osteoartrite ou osteoartrose (TEIXEIRA-SALMELA et al., 2003).

No pós-operatório de cirurgias como a artroplastia ou para a recuperação de pacientes com algum tipo de trauma, as técnicas fisioterapêuticas mais comuns empregadas na reabilitação: a terapia passiva, a ativo-assistida e a ativa. Essas modalidades variam de acordo com o nível de atividade requerido pela pessoa e, principalmente, com a gravidade da lesão sofrida. A principal característica da modalidade passiva é que o paciente não está envolvido na movimentação, ou seja, isto depende da intervenção do fisioterapeuta ou de uma máquina que irá realizar a Movimentação Passiva Contínua (CPM, do termo em inglês: *Continuous Passive Motion*) deste paciente. Já na terapia ou Movimentação Ativa Contínua (CAM, do termo em inglês: *Continuous Active Motion*), o movimento é obtido com a combinação de esforços do paciente e do fisioterapeuta e/ou de uma máquina. Por fim, na modalidade ativa, somente o paciente realiza os movimentos sem a intervenção de máquinas e/ou do fisioterapeuta na aplicação da terapia. A grande vantagem do CPM é a possibilidade de iniciar o processo de terapia da mobilidade do paciente poucas horas após o processo cirúrgico, dependendo do caso (CALLEGARO et al., 2010), (RIVERA; ORTEGA; BAUTISTA, 2013).

O Serviço de Fisioterapia do HSL (Hospital São Lucas) conta atualmente com máquinas de CPM, que possibilitam a aplicação da terapia com auxílio de profissionais da área. Entretanto, este é um equipamento limitado e possui um sistema de controle em malha aberta, ou seja, necessita de um profissional que faça a programação e os ajustes necessários para a realização dos exercícios para que então o dispositivo possa ser utilizado. (CALLEGARO et al., 2010), (LENSSEN et al., 2008).

A estratégia proposta neste trabalho pode ser aplicada em equipamentos de CPM, como o do HSL, de forma a promover melhorias. Uma delas, é a utilização dos sinais de eletromiografia de superfície (sEMG, do termo em inglês: *Surface Electromyography*) como forma de monitorar a resposta muscular do paciente aos estímulos proporcionados pela

máquina de CPM. Os sinais eletromiográficos propostos no projeto são coletados com a utilização de eletrodos colocados sobre a pele do paciente (método não invasivo), os quais captam as variações elétricas das fibras musculares, em momentos como a contração muscular. Através desses sinais fisiológicos e o seu correto processamento, é possível extrair características importantes para a determinação e progressão do tratamento fisioterapêutico.

No sinal eletromiográfico (EMG) de um paciente é possível encontrar padrões de fadiga que podem ser utilizados como critério de parada no processo de fisioterapia, por exemplo. Outra característica que pode ser encontrada no EMG é o limiar força, ou seja, o ponto em que o paciente não consegue completar o exercício por falta de força. Dessa forma, é possível programar a máquina de CPM para auxiliar o paciente a terminar o exercício, assim transformando a terapia passiva-contínua em ativo-assistida (RIVERA; ORTEGA; BAUTISTA, 2013), (KONRAD, 2005).

O conceito de *machine learning* (ML) surge da necessidade de se resolver problemas até então solucionados com o emprego de complexos algoritmos difíceis de serem escritos devido à natureza do problema. Com o emprego de técnicas de *machine learning* é possível construir uma boa aproximação para um determinado problema "aprendendo com os seus dados", ou seja, utiliza-se uma grande quantidade de dados coletados do problema e com os quais um computador (*machine*) possa "aprender" (*learn*) e assim obter algoritmo capaz de obter uma solução para o problema (ALPAYDIN, 2009).

As redes neurais artificiais, do inglês *artificial neural networks* (ANN), são uma das ferramentas da inteligência artificial que permitem que o aprendizado das máquinas ocorra. Algumas das ANN seguem o modelo do cérebro humano, ou seja, são arranjos de neurônios artificiais interligados, que são ótimas ferramentas para classificação e para busca de padrões. Por este motivo, são ferramentas adequadas para a análise de sinais eletromiográficos, nos quais busca-se encontrar padrões característicos (ALPAYDIN, 2009).

Devido a uma crescente demanda por dispositivos automatizados na área médica, o objetivo principal deste estudo é o desenvolvimento de uma estratégia de identificação e classificação de padrões de esforços musculares contidos em sinais eletromiográficos e utilizando-os no sistema de controle de máquinas de CPM. Através da aplicação desta estratégia em máquinas de CPM é possível que a ela opere em malha fechada, ou seja, ajuda o usuário a realizar o processo de fisioterapia, transformando o Movimento Passivo Contínuo em Ativo Assistido (CALLEGARO et al., 2010), (RIVERA; ORTEGA; BAUTISTA, 2013), (HO; CHEN, 2006), (HO; CHEN, 2008).

2 OBJETIVOS

2.1 Objetivo geral

Este trabalho, tem como objetivo estudar o sinal de EMG de um músculo isolado (vasto lateral) para controlar uma máquina de CPM/CAM por meio de inteligência artificial.

2.1.1 Objetivos específicos

Nesse contexto, os objetivos específicos deste trabalho, de modo a atingir o objetivo geral desta dissertação são:

- Realizar o pré-processamento do sinal eletromiográfico;
- Caracterizar os sinais de EMG;
- Projetar a rede neural artificial;
- Projetar o sistema de controle;
- Simular o funcionamento do sistema
- Validar o sistema de controle e da RNA;

2.2 Escopo do trabalho

A estratégia de controle proposta neste trabalho, é uma simulação do funcionamento de uma máquina CAM, que utiliza o sistema de controle baseado no *feedback* do usuário (EMGs musculares classificados em força). A contribuição deste trabalho para a área engenharia biomédica e biomecânica é, comprovar a possibilidade de utilizar o sinal de EMG de um músculo isolado para controlar uma máquina de CPM/CAM utilizando inteligência artificial, através de uma simulação.

Neste contexto, a estratégia de identificação e classificação dos sinais eletromiográficos utilizada para criar um *feedback* para o sistema de controle de uma máquina CPM, com o objetivo de transformá-la em CAM, é válida somente *offline*. O modelo da máquina de CPM/CAM utilizado no projeto do sistema de controle deste trabalho foi uma adaptação da abordagem proposta por Ho e Chen (2009), em que não são considerados os atritos estáticos e dinâmicos, bem como não-linearidades presentes em um sistema real.

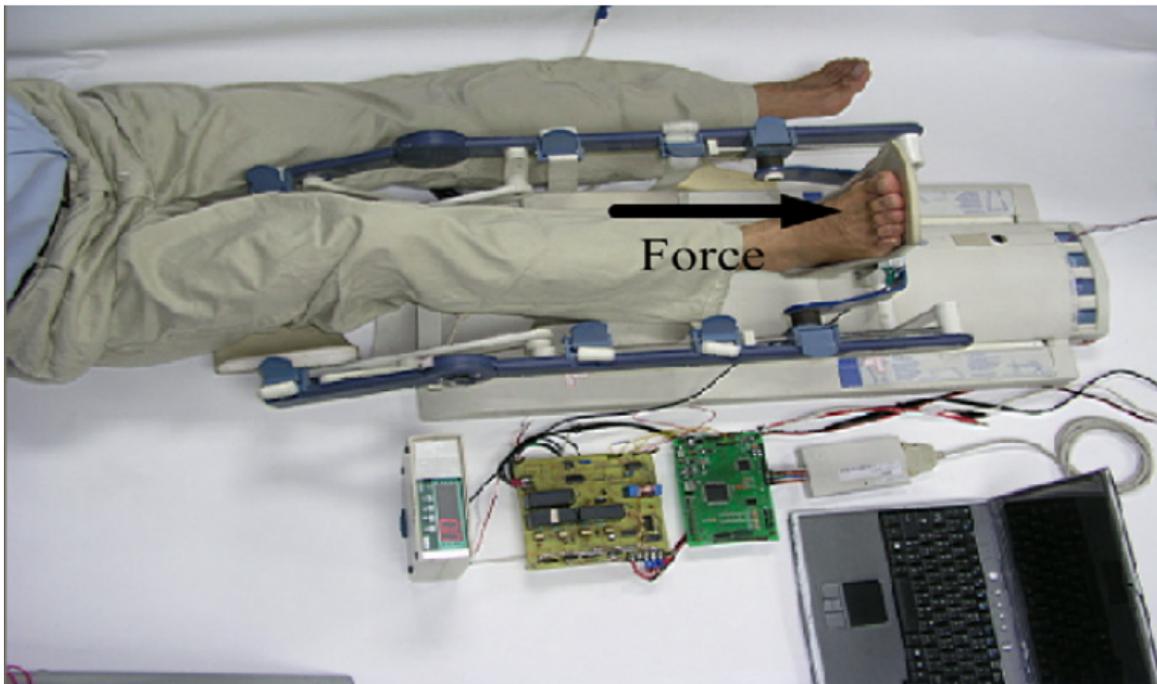
3 ESTADO DA ARTE

No momento, existem vários tipos de máquinas de CPM (do termo em inglês: *Continuous Passive Movement*) disponíveis no mercado; Todas essas máquinas têm o mesmo conceito, realizam a terapia contínua passiva em tornozelos, joelhos, cotovelos ou ombros de pacientes. Essas máquinas são sistemas de controle em malha aberta, o que significa que não existem sinais de *feedback*, portanto, não existem um sistema no equipamento que controle a movimentação. Dessa forma, a medição da ativação muscular em tempo real do exercício (CPM) no processo de fisioterapia do paciente é comprometida.

Essencialmente, um equipamento CAM (do termo em inglês: *Continuous Active Movement*) usa um modelo tradicional de máquina de CPM combinado com sensores (para adquirir o *feedback* desejado do usuário) e um sistema de controle em malha fechada, que permita controlar ou auxiliar o usuário durante a movimentação. Ho e Chen (2006) construíram uma máquina CAM (figura 1) de joelho usando sensores de força e posição angular acoplados ao equipamento, como forma de obter um *feedback* para o seu sistema de controle. Como estratégia de controle principal, eles utilizaram um controlador PID (HO; CHEN, 2006).

Em outro estudo, Ho e Chen (2009) propuseram um controlador adaptativo FNN (*Fuzzy-Neural Network*) para sua máquina de CAM (figura 1. Essa estratégia de controle híbrida (testado com dois pacientes) permitiu ajustar e controlar o esforço do paciente durante a terapia, com base nas medidas de força e posição (sensores) e suas estimativas. Além disso, o controlador adaptativo proposto, devido à sua capacidade de aprender com dados (inteligência artificial), pôde lidar com as não linearidades do sistema (HO; CHEN, 2009).

Figura 1 – Dispositivo CPM/CAM de Ho e Chen

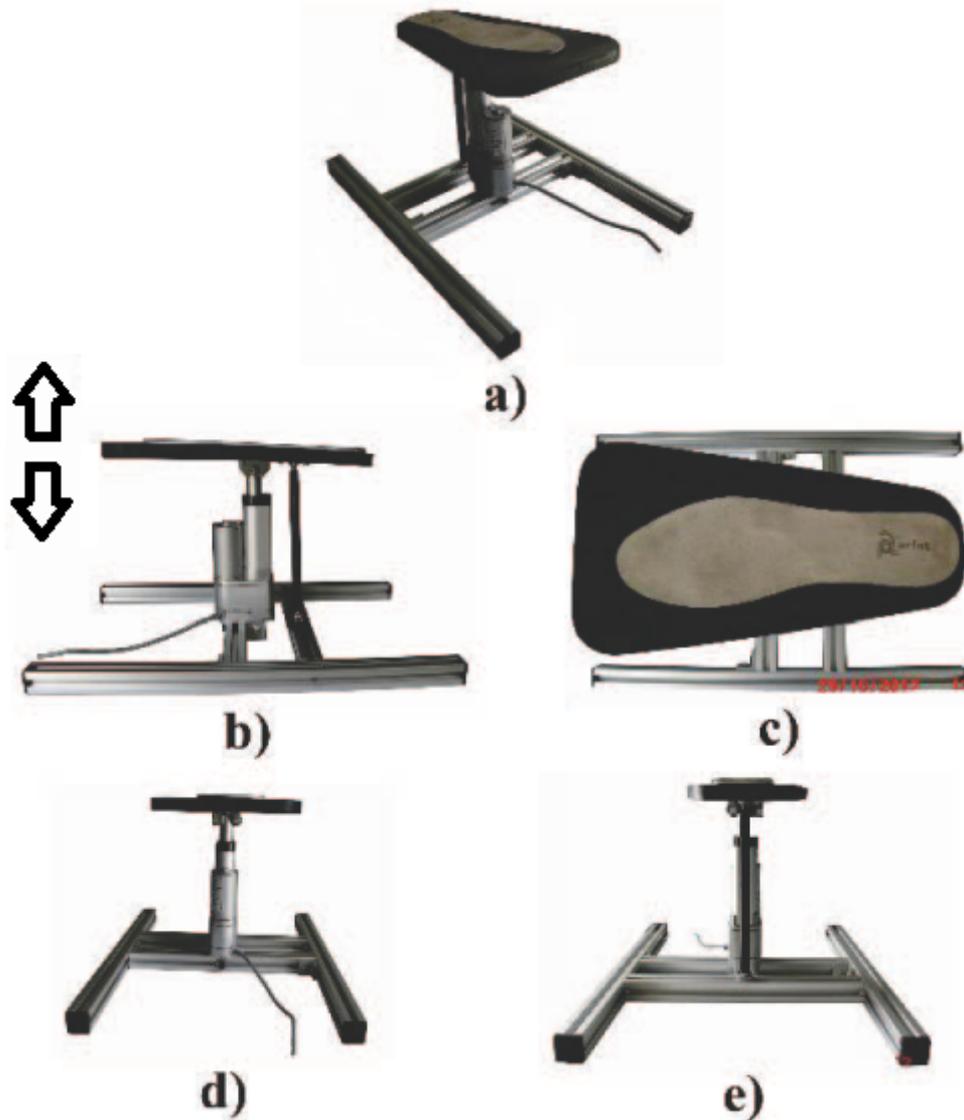


Fonte: (HO; CHEN, 2009)

Um sinal mioelétrico (sinal muscular) carrega várias informações sobre músculos (energia, amplitude, duração máxima do pico) que podem ser usadas para o diagnóstico de disfunções neuromotoras. Portanto, a análise EMG é amplamente utilizada em estudos biomédicos, por exemplo, ergonomia, ciência do esporte, reabilitação e fisioterapia (YOUSEFI; HAMILTON-WRIGHT, 2014), (KONRAD, 2005). Nessa conjuntura, pesquisas científicas sobre como construir sistemas automatizados CAM, usando inteligência artificial (IA) associada à análise EMG aumentaram significativamente.

Nesse contexto, a análise eletromiográfica foi adotada por Rivera et al.(2013) na máquina de CPM do tornozelo, mostrada na figura 2, como forma de monitorar a atividade muscular do tornozelo do paciente durante os movimento ativo contínuo. O dispositivo, se movimenta para cima e para baixo continuamente auxiliando o usuário durante o processo terapêutico (figura 2 (b)). A ideia por trás do estudo era verificar a eficiência da terapia, enquanto o paciente realizava o movimento auxiliado por um sistema de controle PID (RIVERA; ORTEGA; BAUTISTA, 2013).

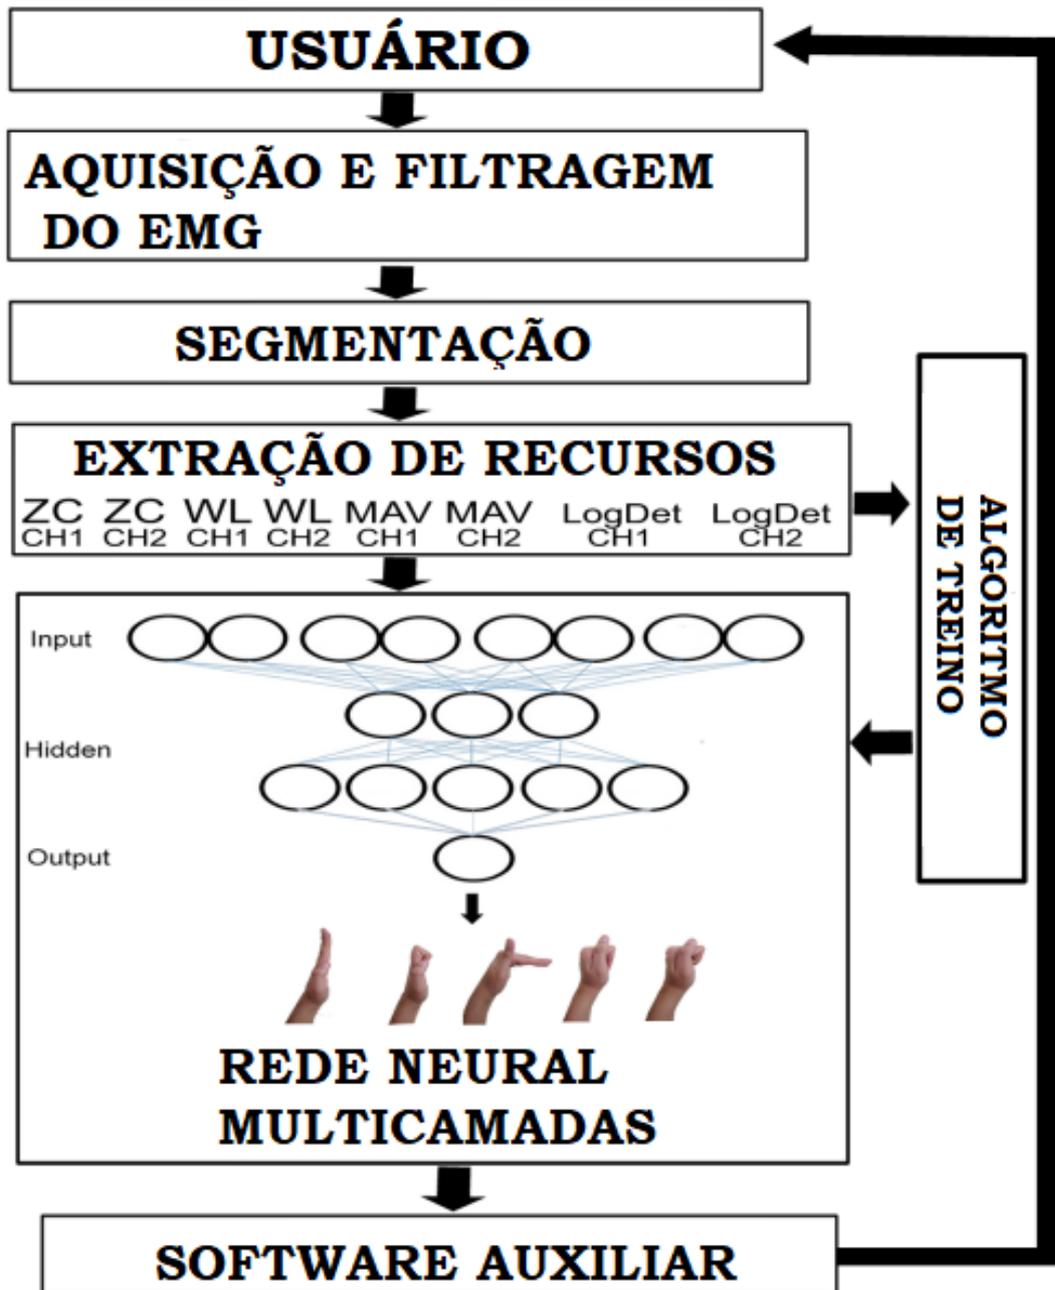
Figura 2 – Dispositivo CPM para tornozelos



Fonte: Adaptado de (RIVERA; ORTEGA; BAUTISTA, 2013)

Seguindo esses conceitos, Amrani et al.(2017) propuseram um dispositivo de reabilitação para mãos baseado em um sistema de controle mioelétrico que usava sinais de EMGs como realimentação (Figura 3). Em seu estudo, eles criaram previamente padrões de movimentação da mão para treinar uma rede neural artificial. Após isso, era possível identificar por meio do seu *software*, qual era o gesto que o paciente estava fazendo. Eles usaram cinco pacientes para coletar os sinais sEMG (eletromiografia de superfície) e construir um classificador de RNA; o algoritmo alcançou 95 % de precisão na classificação (usando 4 atributos) dentro de 300ms de tempo de processamento. (AMRANI et al., 2017).

Figura 3 – Máquina para reabilitação manual de Amrani



Fonte: Adaptado de (AMRANI et al., 2017)

Outro trabalho envolvendo análise EMG foi proposto por CUI et al.(2017), onde eles desenvolveram um algoritmo de reconhecimento de padrões com base em redes neurais artificiais para membros superiores. Atributos, são informações utilizadas para caracterizar um sinal, como por exemplo, energia, comprimento de onda, frequência máxima etc. Os atributos são geralmente utilizados para criar um padrão do sinal para ser aplicado em um classificador baseado em inteligência artificial (RNA). Em seu estudo, eles usaram EMGs de ombros e cotovelos de dez indivíduos, e extraíram 4 atributos de ativação

poucas máquinas de CPM para joelho que podem executar o movimento ativo contínuo e nenhuma delas utiliza o sinal EMG de um músculo isolado do paciente para criar um *feedback* para o sistema de controle, como este estudo propõe.

Visto que o conceito de aprendizado de máquina tornou-se uma solução para problemas em várias áreas, especialmente naquelas em que são necessárias soluções rápidas e dinâmicas. Na engenharia biomédica, as redes neurais artificiais são usadas principalmente em situações que exigem, reconhecimento facial, impressão digital, reconhecimento de voz e análise de EMG (ALPAYDIN, 2009), (HAYKIN et al., 2009).

A tabela 1, evidencia que uma das ferramentas do aprendizado de máquina (MLT, do inglês: *Machine Learning Tools*) mais aplicadas nas construções de classificadores (na área de caracterização EMG) são as redes neurais artificiais (RNA) (YOUSEFI; HAMILTON-WRIGHT, 2014). Esses classificadores de RNA podem atingir alta precisão (95%) de classificação na identificação de padrões EMG com tempo de processamento (na ordem de milissegundos) suficiente para viabilizar aplicações em tempo real. Geralmente, os classificadores de RNA usam métodos semelhantes de processamento de sinal, por exemplo, aquisição de dados, filtragem e suavização, a única diferença é a caracterização (AMRANI et al., 2017), (NAZMI et al., 2016).

Portanto, uma máquina CAM baseada neste tipo de análise eletromiográfica, pode ajudar os profissionais da área da saúde (fisioterapeutas) a obter um entendimento mais profundo sobre a eficácia do movimento e, conseqüentemente, melhorar o processo de recuperação do paciente (ARTROMOT, 2013), (KINETEC, 2009).

4 FUNDAMENTAÇÃO TEÓRICA

Para um melhor entendimento deste estudo, foram necessários compreender conceitos de pelo menos três áreas do conhecimento: medicina, fisioterapia e engenharia. Dessa forma, foi fundamental a realização de um aprofundamento teórico individual sobre os principais tópicos, que juntos se relacionam e formam a fundamentação teórica deste trabalho. Os principais tópicos são: osteoartrite, movimentação passiva-continua, eletromiografia, caracterização de sinais de EMG baseados em inteligência artificial, um tópico sobre o sistema de controle e por fim uma rápida passagem sobre de um sistema genérico de identificação e controle baseado em EMG. Esses tópicos serão abordados mais detalhadamente neste referencial teórico.

4.1 Osteoartrite

A osteoartrite (OA) é uma doença articular degenerativa que afeta cerca de 65% das pessoas com mais de 65 anos de idade. Além do fator idade, a locomoção diária das pessoas, o gênero e raça também contribuem para o seu aparecimento. A maior frequência de OA ocorre nos membros inferiores como joelhos, quadris e pés, mas também pode aparecer em outras articulações, como nas mãos, ombros e coluna vertebral. Embora a OA não tenha cura, ela pode ser controlada por procedimentos médicos e farmacológicos. A osteoartrite é um problema de saúde pública, que se não tratada provoca a redução da mobilidade dos portadores. Dessa maneira, a OA pode levar as pessoas a quadros de sedentarismo que, por sua vez, trarão consigo outros problemas (LEMURA; DUVILLARD, 2006), (MEDICINE et al., 2004).

4.2 Movimentação passiva contínua

A Movimentação Passiva Contínua (CPM, do termo em inglês: *Continuous Passive Movement*) é um tipo de terapia indicada por fisioterapeutas e ortopedistas para pessoas que sofreram lesões musculares ou em articulações. Esta técnica foi proposta originalmente por Robert Salter (KISNER; COLBY, 2009) e consiste de um dispositivo mecânico conhecido como máquina de CPM que realiza movimentos pré-programados durante um determinado intervalo de tempo. O dispositivo mostrado na figura 5, é um exemplo de uma máquina de CPM comercializada. Essa máquina permite a realização de uma movimentação suave da articulação desejada (joelho neste modelo de equipamento), sem necessidade de esforço por parte do paciente, (TAN, 2006).

Figura 5 – Máquina de CPM comercial



Fonte: (KINETEC, 2009)

A Movimentação Passiva Contínua consiste da aplicação de uma força externa por meio da máquina de CPM, que realiza movimentos contínuos no paciente imobilizado, com o intuito de acelerar a recuperação das áreas afetadas, inclusive no pós-operatório de cirurgias como a artroplastia total do joelho ou cotovelo (CALLEGARO et al., 2010), (LENSSSEN et al., 2008). O CPM é efetivo na redução dos efeitos negativos causados pela imobilização da articulação pós-cirúrgica. Entre os vários benefícios da utilização do CPM pode-se citar (KISNER; COLBY, 2009), (TAN, 2006):

- Acelera o processo de recuperação do controle motor voluntário da musculatura adjacente à lesão ;
- Reduz o tempo necessário para a recuperação da articulação;
- Acelera a recuperação da amplitude de movimento (Range of Movement - ROM);
- Diminui as dores do pós operatório;
- Melhora a cicatrização e a recuperação da cartilagem;
- Aumenta a lubrificação da junta com o líquido sinovial;
- Previne adesões e a formação de contraturas;

4.3 Movimentação ativa contínua

Por outro lado na Movimentação Ativa Contínua (CAM, do termo em inglês: *Continuous Active Movement*), existe a coparticipação do paciente durante a realização da terapia, ou seja, parte do exercício é realizada pelo paciente e parte por um equipamento, no caso uma máquina CAM. O equipamento CAM, construtivamente similar a uma máquina de CPM porém contém elementos que possibilitam a interação do paciente, geralmente um motor elétrico conforme pode ser visto na figura 6 (ARTROMOT, 2013).

Figura 6 – Máquina de CAM comercial



Fonte:(ARTROMOT, 2013)

Estudos que comparam as terapias CPM e CAM, afirmam que CAM em relação ao CPM apresenta uma melhoria significativa na recuperação do paciente se aplicado na primeira semana pós-operatória da cirurgia de artroplastia total do joelho (FRIEMERT et al., 2006). Outros estudos comparativos demonstram que a utilização do CAM deve ter prioridade em relação a Movimentação Passiva contínua, pois apresentam resultados melhores que o CPM em termos de flexibilidade, dor e qualidade de vida.(SCHULZ et al., 2018), (FRIEMERT et al., 2001)

A seguir são citados alguns dos benefícios da aplicação da Movimentação Ativa Contínua (CAM) ([ARTROMOT, 2013](#)):

- Reabsorção mais rápida de hematomas;
- Melhor circulação sanguínea e linfática;
- Profilaxia para síndromes de trombo e embolia;
- Terapia resistente durante a reabilitação;
- Acelera a coordenação e a percepção sensorial após a cirurgia;

4.4 Eletromiografia

Os sinais mioelétricos são sinais musculares formados por variações fisiológicas na diferença de potencial eletroquímico das fibras musculares (estado de repouso e ação) e são estudados através da eletromiografia. Segundo Konrad, "(· · ·) é o estudo da função muscular através da investigação do sinal elétrico que os músculos emanam (· · ·)" ([KONRAD, 2005](#)). A definição de Konrad nos leva a analisar a origem desses sinais emanados pelos músculos. Os sinais eletromiográficos musculares são emitidos quando as fibras musculares são contraídas. Essas contrações são controladas pelo cérebro através da unidade motora.

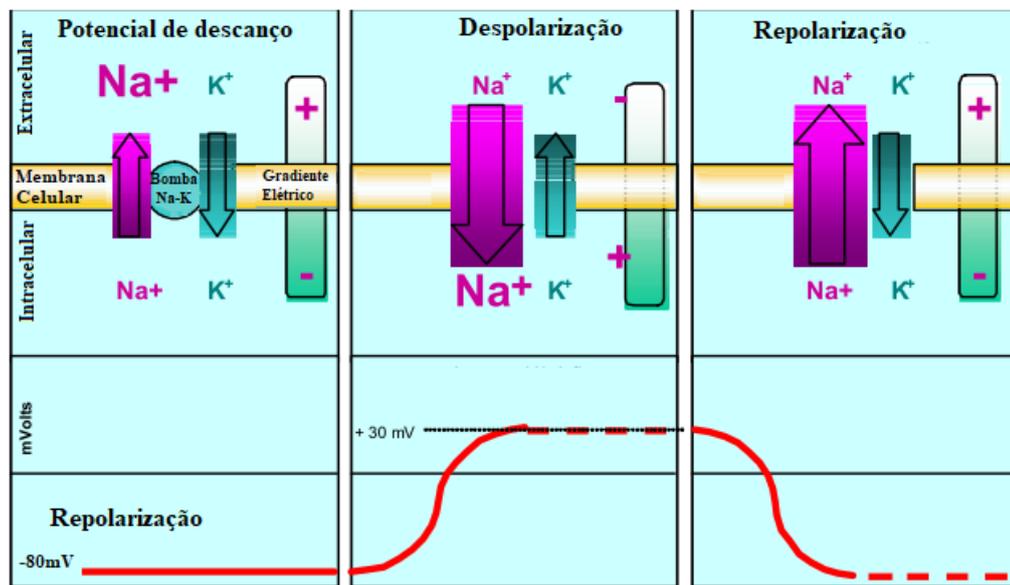
As unidades motoras são formadas por um neurônio motor alfa e as fibras musculares que ele inerva. Isso se dá em nível de corno anterior da medula espinal. O córtex motor primário (no cérebro), por meio das *CMcells* (corticomotoneuronais) presentes no trato cortico-espinal controla direta (motoneurônio alfa) e indiretamente (interneurônio inibitório Ia, por exemplo), a circuitaria do neurônio motor inferior na medula que, por sua vez, interfere na unidade motora ([KANDEL et al., 2000](#)).

- Unidade muscular: Conjunto de fibras inervadas por um único motoneurônio alfa.
- Unidade motora: É a unidade muscular com o motoneurônio alfa que a inerva.
- Placa Motora: Conexão entre o motoneurônio alfa e uma fibra muscular alvo.

Nesse contexto, estudos em áreas como reabilitação, ergonomia ou esportes, podem contar com a eletromiografia, uma ferramenta muito poderosa na avaliação do estímulo muscular das pessoas no que diz respeito da sua interação com o meio ambiente. Desse modo, a eletromiografia abre uma série de possibilidades para pesquisas envolvendo doenças ocupacionais, design de produtos, biomecânica e a reabilitação pós-cirúrgica.

O fenômeno que envolve o controle dos neurônios na excitabilidade das fibras musculares é explicado através do modelo das membranas semi-permeáveis. Esse modelo explica as trocas dos íons de sódio (Na^+) e potássio (K^+) na membrana celular através do mecanismo chamado de bomba sódio-potássio. Como é possível observar na figura 7 íons ocorrem até um certo ponto, pois esses íons se deslocam conforme o estado do gradiente eletroquímico, gerando despolarização e repolarização. Quando esse fenômeno o potencial elétrico é elevado de $-80mV$ (condição de repouso) à $30mV$ (despolarização) (KONRAD, 2005)..

Figura 7 – Ciclo de despolarização e repolarização da membrana muscular



Fonte: Adaptado de (KONRAD, 2005)

A combinação desse processo por todas as unidades motoras (UM) forma o sinal eletromiográfico muscular. Assim, um $EMG(t)$ pode ser representado pelo somatório do potencial elétrico de n a m unidades motoras mais uma parcela de ruídos $\eta(t)$. Esses ruídos podem ser de origem biológica assim como do equipamento de coleta dos dados. Desse modo, o sinal de uma contração muscular capturado por um eletrodo é matematicamente representado pela equação 4.1 (YOUSEFI; HAMILTON-WRIGHT, 2014).

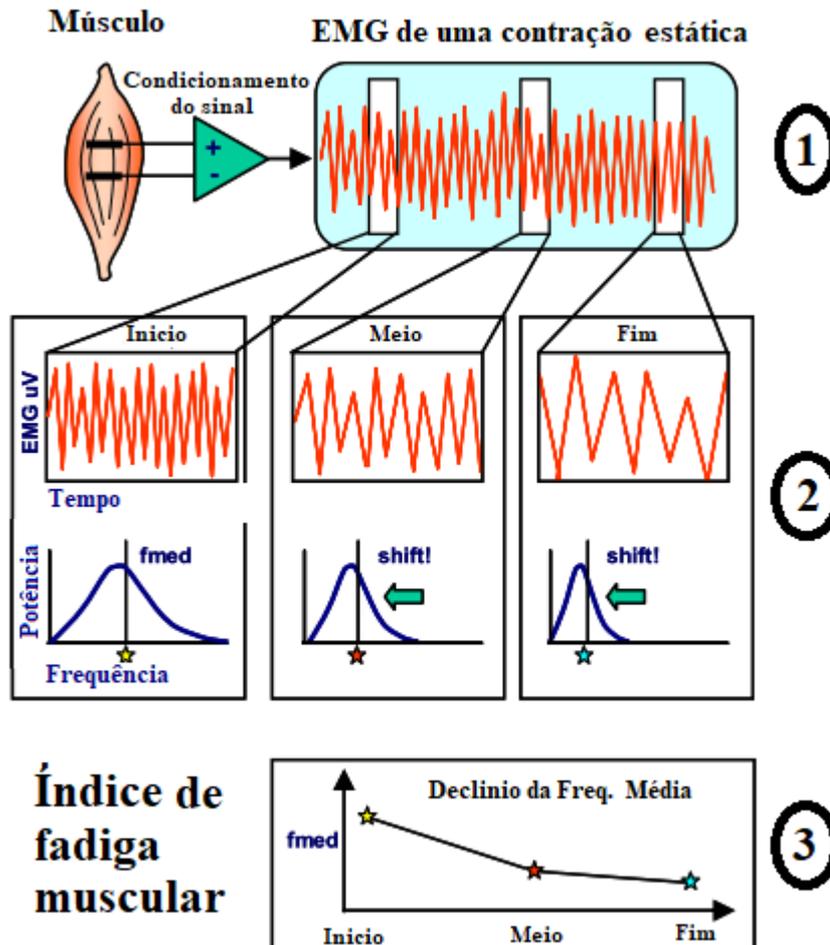
$$EMG(t) = \sum_{m=1}^n UM(t) + \eta(t) \quad (4.1)$$

4.4.1 Decomposição de um sinal eletromiográfico

A análise da origem do sinal eletromiográfico muscular, por meio de eletrodos (de superfície, por exemplo) permite captar e armazenar essas variações de potencial elétrico. Devido ao fato do sinal elétrico muscular ser muito pequeno e bastante suscetível a ruídos,

este sinal é condicionado (filtrado e amplificado) por um equipamento chamado eletromiógrafo, antes de ser armazenado e processado em um computador digital (KONRAD, 2005).

Figura 8 – Processo simplificado de aquisição e caracterização de um EMG



Fonte: Adaptado de (KONRAD, 2005)

A figura 8 mostra um esquema de como são coletadas, processadas e extraídas informações, por exemplo, da fadiga muscular, de um sinal eletromiográfico. O esquema é dividido basicamente em três etapas:

- Posicionamento dos eletrodos nos músculos desejados e o condicionamento do sinal (eletromiógrafo) para ser processado num computador;
- Análise do espectro em frequência do sinal, por meio de técnicas de processamento digital de sinais;
- Análise da relação da frequência média do sinal com a fadiga muscular.

Como mencionado, as técnicas de processamento digital de sinais estão presentes na análise do EMG. Uma das mais utilizadas é a FFT (*Fast Fourier Transform*). Após realização da FFT é possível analisar o comportamento do EMG no domínio frequência e, portanto, encontrar padrões de fadiga de forma não invasiva. Um dos padrões buscados é o declínio da frequência média do sinal, conforme o exercício progride. Por exemplo, em uma série de exercícios de hipertrofia muscular (levantamento de peso), esta série pode ser dividida em três faixas: início, meio e fim.

Como pode ser observado na figura 8 na segunda etapa da série, a fadiga muscular (fisiologicamente esperada) do individuo conforme o exercício progride no tempo é percebida no domínio frequência. Dessa maneira, na terceira etapa é possível construir um gráfico que envolve as frequências medias de cada etapa do exercício, e conseqüentemente, é possível notar que existe uma tendência decrescente (KONRAD, 2005).

Além da análise em frequência, no processo de caracterização de sinais eletromiográficos, existem outras informações disponíveis no mesmo, um sumário de outras características mais buscadas pode ser observado a seguir (YOUSEFI; HAMILTON-WRIGHT, 2014):

- Energia do sinal e Amplitude;
- Duração do pico da amplitude máxima;
- Duração de início e fim da contração;
- Taxas de disparo das contrações.

4.5 Caracterização de sinais de EMG baseados em IA

A primeira ideia concreta de inteligência artificial (IA) surgiu na década de 50, quando se pensava na criação de máquinas que pudessem pensar de forma inteligente, tendo como objetivo imitar ou até mesmo superar o pensamento humano. Dentre as várias definições de IA, segundo George F. Luger, "(· · ·) inteligência artificial (IA) pode ser definida como o ramo da ciência da computação que se ocupa da automação do comportamento inteligente (· · ·)" (LUGER, 2004). Com base nessa definição, observa-se que a inteligência artificial é fundamentada, estudada e aprofundada dentro da ciência da computação, pois é neste campo que as aplicações práticas da IA são viabilizadas por meio de linguagens e técnicas de programação, assim como na construção de algoritmos (LUGER, 2004).

Anos depois, como uma parte que integra o conceito de inteligência artificial surge o conceito de *machine learning*, ou aprendizado de máquina, em que basicamente a ideia era ensinar o computador a aprender por si próprio utilizando dados disponíveis sobre o

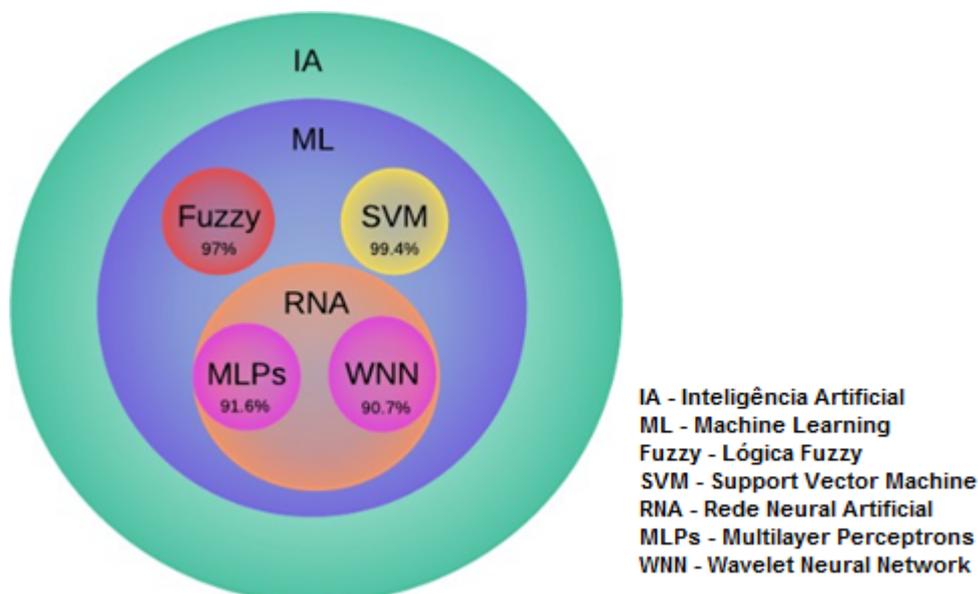
problema. Logo de início, o *machine learning* demonstrou sua importância para aplicações práticas da IA, pois a habilidade de aprender é um requisito primordial aos sistemas que se dizem inteligentes (LUGER, 2004).

Do ponto de vista de Eethem Alpaydin, "(· · ·) *machine learning* é programar os computadores para otimizar o critério de desempenho utilizando dados passados ou exemplos (· · ·)"(ALPAYDIN, 2009). Essa definição mais prática e objetiva, nos mostra que o aprendizado de máquina é utilizado em casos nos quais não se pode diretamente escrever um algoritmo para um determinado problema, sendo necessária experiência ou inserção de dados sobre o mesmo.

Desse modo, o aprendizado de máquina é necessário, quando as pessoas não têm expertise suficiente para modelar o problema devido a sua complexidade, como por exemplo no reconhecimento de imagens, na distinção de sotaques em discursos ou ainda particularidades em caligrafias. Por outro lado *machine learning* pode ser útil também nos casos em que temos vários algoritmos que solucionam o problema, mas se quer buscar o mais otimizado possível (ALPAYDIN, 2009).

Atualmente, métodos que "aprendem com os dados", tem estado cada vez mais presentes em todas as áreas do conhecimento humano, entre elas na engenharia biomédica e na identificação de padrões de EMG, dentre outros. Neste contexto, o processo de extração de informações de um EMG requer a utilização de ferramentas que o *machine learning* oferece. A figura 9, mostra algumas das técnicas, de modo geral, mais adotadas (com suas respectivas acurácias) na caracterização de sinais de EMG muscular (SUBASI, 2013), (YOUSEFI; HAMILTON-WRIGHT, 2014).

Figura 9 – Técnicas do *Machine Learning* mais utilizados na classificação de EMGs



Fonte: Adaptado de (SUBASI, 2013)

4.5.1 Redes neurais artificiais

Os algoritmos de redes neurais artificiais (RNA), são outra ferramenta do *machine learning*, dentre as várias que são utilizadas para "ensinar o computador". Na medicina contemporânea, esses algoritmos são utilizados como ferramenta de auxílio aos profissionais da área. Uma RNA acelera o processo de diagnóstico de uma doença neuromuscular de um paciente, por meio da identificação de padrões de sinais eletromiográficos. As RNAs são bastante utilizadas na medicina devido à sua habilidade de aprender com exemplos, tolerância à incertezas e imprecisões, que surgem na interpretação dos sinais biológicos, como é o caso de EMGs. (SUBASI, 2013), (ALPAYDIN, 2009), (YOUSEFI; HAMILTON-WRIGHT, 2014).

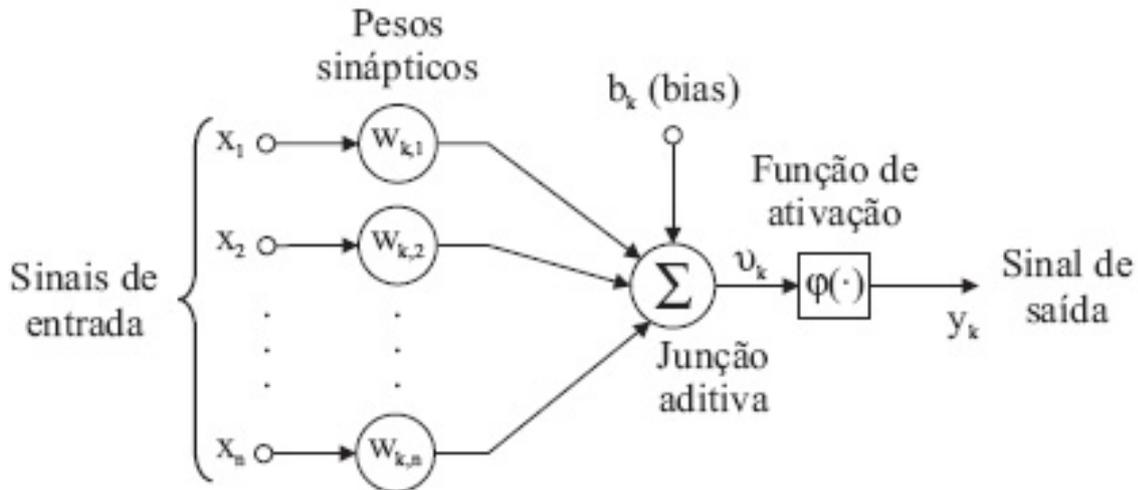
Como o foco deste trabalho é a utilização de uma RNA para a identificação dos padrões eletromiográficos, uma definição sobre redes neurais é necessária. Portanto, Simon Haykin define uma rede neural como sendo, "(· · ·) um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão de armazenar o conhecimento experimental e torná-lo disponível para o uso (· · ·)" (HAYKIN et al., 2009). Desse modo, podemos concluir que uma rede neural artificial se assemelha ao cérebro, basicamente em dois aspectos:

1. O conhecimento é adquirido pela rede neural por meio de um processo de aprendizagem;
2. A força da conexão entre os neurônios (pesos sinápticos) é a responsável pelo armazenamento do conhecimento;

4.5.2 *Multilayer Perceptrons*

Em meio aos vários arranjos possíveis para as redes neurais, um muito usual e bastante consistente na identificação de padrões eletromiográficos é o MLP (*multilayer perceptron*) também conhecido como *feedforward*. Outras arquiteturas bem usuais são: RNAs probabilísticas, RNAs recorrentes (*recurrent neural network*), dentre outras. Segundo Yousefi et al. (2014), as MLPs treinadas com o algoritmo supervisionado *backpropagation* (BP) apresentam um desempenho na identificação de padrões em EMGs na faixa de 90%. Além disso, RNAs treinadas com o BP tendem a ser mais consistentes em comparação a outros tipos de treinamento (YOUSEFI; HAMILTON-WRIGHT, 2014), (HAYKIN et al., 2009).

Figura 10 – Modelo de um neurônio artificial



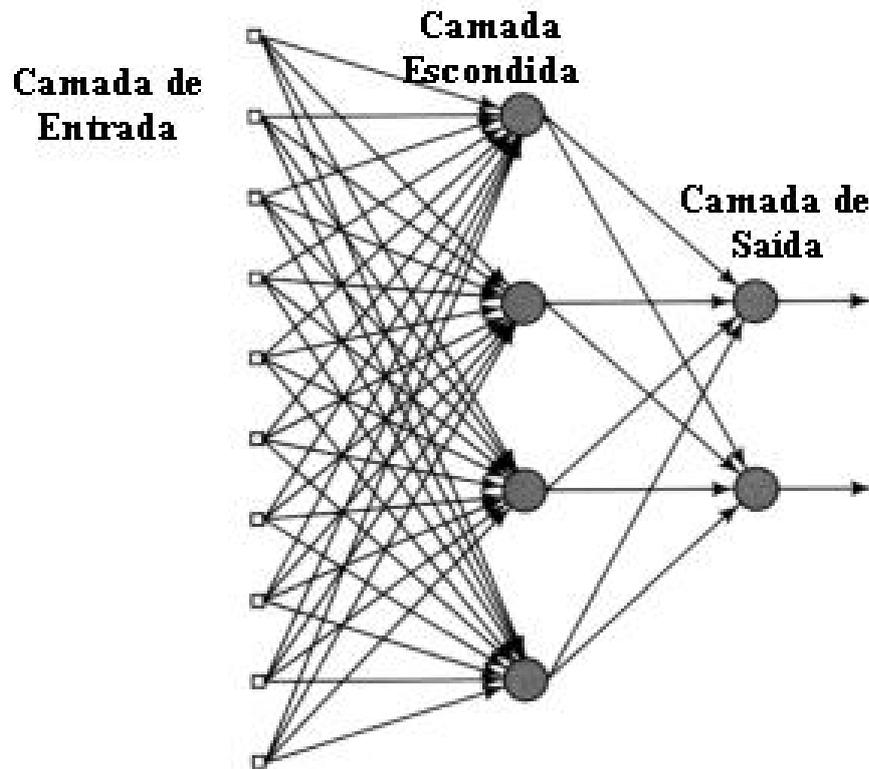
Fonte: Adaptado de (HAYKIN et al., 2009)

O modelo de neurônio artificial apresentado na figura 10 é construído com base nas definições apresentadas na seção anterior (4.5.1) e, assim como o neurônio humano, que é um sistema não-linear. Esse modelo de neurônio serve de base para a construção das diferentes arquiteturas apresentadas (HAYKIN et al., 2009).

Os sinais de entrada x_n dos neurônios são ponderados pelos pesos sinápticos $W_{k,n}$ (podendo esses serem valores tanto positivos como negativos), sendo k o índice do neurônio na camada escondida (ou na camada de saída) (k -ésimo neurônio) e n o índice da entrada na camada de entrada (n -ésima entrada). Após os sinais passarem pelos pesos sinápticos, eles são somados na junção aditiva formando o sinal v_k . Nesta junção aditiva pode-se ainda adicionar o valor b_k que é conhecido como bias e tem a função de aumentar ou diminuir o valor do sinal v_k , antes deste passar pela função de ativação. O sinal de saída y_k é finalmente obtido após a passagem pela função de ativação ϕ , que limita em amplitude (saturação) o sinal a um valor finito, geralmente normalizado com valores entre $[0,1]$ ou $[-1,1]$ (HAYKIN et al., 2009).

O modelo de neurônio artificial mostrado na figura 10, como mencionado anteriormente, pode ser estruturado de diversas formas; contudo, é necessário ter em mente que essa estrutura está diretamente relacionada com o modo de aprendizagem que será utilizado posteriormente no treinamento da RNA. Um exemplo de uma MLP com uma camada oculta pode ser observado na figura 11. Nesse modelo de rede neural, os neurônios são conectados em camadas separadas, sendo elas respectivamente: entrada, oculta e de saída (HAYKIN et al., 2009).

Figura 11 – Rede neural com camadas ocultas



Fonte: Adaptado de (HAYKIN et al., 2009)

No processo de criação de uma rede neural, um dos parâmetros mais importantes a serem observados é o número de neurônios na camada escondida. Contudo, esse parâmetro é difícil de se estabelecer e, geralmente, é escolhido de forma empírica ou por tentativa e erro, de uma forma que atenda os requisitos desejáveis do projeto. A equação 4.2, mostra uma das fórmulas utilizadas como base para a escolha do número de neurônios da camada escondida de uma RNA, onde, N_n representa o número de neurônios desejados na camada escondida, in é o número de neurônios da camada de entrada, out o número de neurônios da camada de saída, e θ uma constante arbitrária de ajuste (CUI et al., 2017).

$$N_n = \sqrt{in + out} + \theta \quad (4.2)$$

4.6 Sistema de Controle

De modo geral, controlar um processo significa manter as variáveis controláveis da planta dentro de seus limites de operação. Dessa forma, o objetivo de um controlador é atuar nas variáveis do processo (planta), de forma a atingir ou manter determinados requisitos (TORGA, 2018). Como cada processo possui características diferentes, o modelo matemático do processo muda, conseqüentemente as variáveis a serem controladas se

alteram. No caso de uma máquina de CPM/CAM, o principal objetivo é controlar a posição (deslocamentos lineares/ angulares) de forma robusta. Portanto, uma avaliação de estabilidade se faz necessária durante o projeto do sistema de controle. Neste trabalho, a análise de estabilidade e a representação do modelo do processo, bem como o projeto do sistema controle, são realizados no domínio de Laplace (domínio frequência), representados pela variável s .

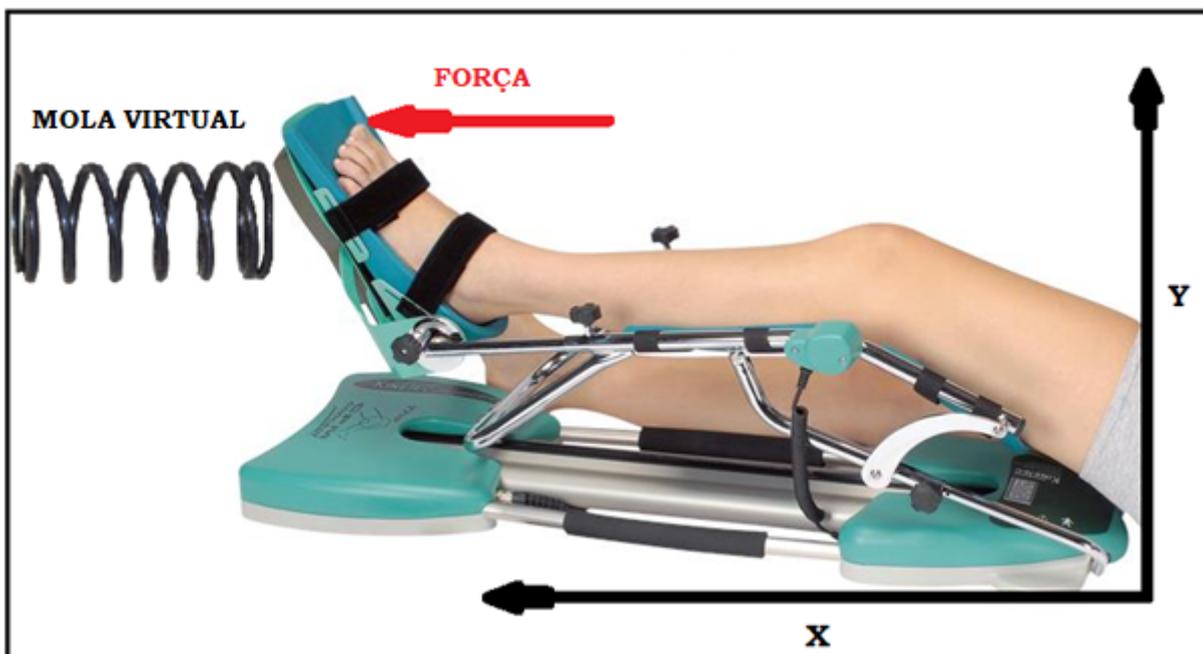
4.6.1 Modelagem matemática de uma máquina de CPM/CAM

A máquina de CPM é um tipo de manipulador eletromecânico com dois graus de liberdade, sendo eles translações nos eixos X e Y, como pode ser visto no esquema da figura 12. A fim de modelar esse sistema é necessário considerar não só o mecanismo em si, mas também sua interação com o corpo humano (HOGAN, 1985).

Essa interação ocorre da seguinte forma: o paciente, ao colocar o membro na plataforma e realizar esforço contra o suporte para o pé (pedal), exerce uma força (carga) que movimenta o mecanismo da plataforma. Essa força é medida por meio da eletromiografia e serve como sinal de realimentação (*feedback*) de modo que o sistema realize uma força oposta, a fim de realizar o movimento ativo-assistido (CAM).

Durante o exercício CAM, o paciente tem a impressão de estar pressionando uma mola com o pé. Essa sensação de "mola virtual" oferece mais ou menos resistência ao paciente, conforme definido no sistema de controle (HO; CHEN, 2009).

Figura 12 – Sistema de impedância mecânica-interação máquina de CPM/CAM-paciente



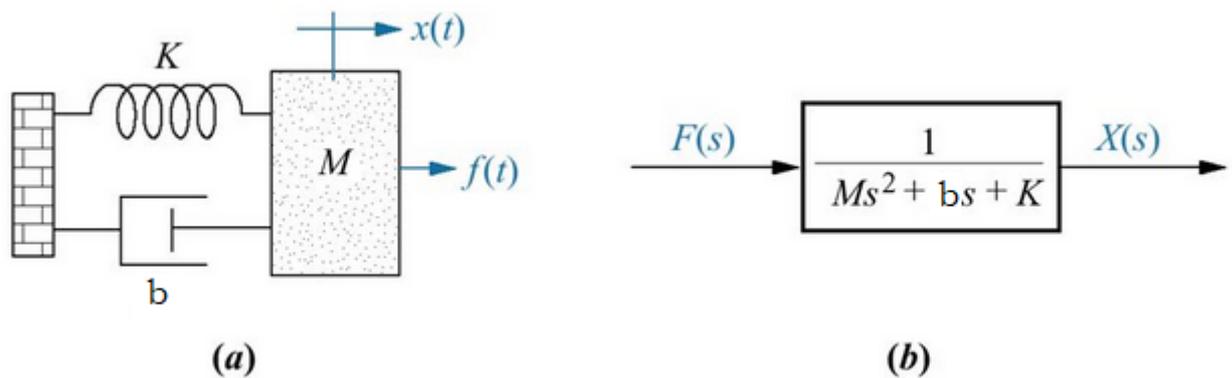
Fonte: Adaptado de (HO; CHEN, 2006) e (KINETEC, 2009)

Assim, a interação entre a força realizada pelo paciente e o mecanismo CPM pode ser aproximada segundo o modelo genérico de "controle de impedância" de Hogan, conforme a equação 4.3 (HOGAN, 1985), sendo F a força aplicada pelo usuário ao mecanismo, que produz um deslocamento linear do sistema, representado por x . A massa do sistema corresponde a M , enquanto b corresponde ao fator de amortecimento, K é a constante da mola e $csgn(\dot{x})$ a fricção não-linear de Coulomb (HO; CHEN, 2008), a aceleração, velocidade e posição são respectivamente, \ddot{x} , \dot{x} e x .

$$M\ddot{x} + b\dot{x} + Kx + csgn(\dot{x}) = F \quad (4.3)$$

Desconsiderando o atrito $csgn(\dot{x})$ da equação 4.3, o modelo da máquina de CPM se resume em um sistema de controle de segunda ordem do tipo massa-mola-amortecedor (m-b-k), conforme a figura 13 (a), bem como seu respectivo diagrama de blocos (b) (NISE, 2007).

Figura 13 – Modelo de impedância de segunda ordem



(a) Sistema m-b-k; (b) Diagrama de blocos. Fonte:(NISE, 2007)

Os coeficientes m-b-k do modelo de segunda ordem da máquina de CPM (eq.4.3), representado por $G_p(s)$ podem então ser obtidos a partir da equação característica 4.4, onde ζ representa o fator de amortecimento e ω_n^2 é a frequência de oscilação natural do sistema (NISE, 2007).

$$G_p(s) = \frac{1}{Ms^2 + 2bs + K} = G_p(s) = \frac{\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2} \quad (4.4)$$

O modelo de referência da máquina de CPM/CAM para o sistema de controle deve ser o mais próximo do real, a fim de evitar desconfortos ao paciente no momento da execução do exercício. Portanto, o *design* do modelo deve evitar oscilações, estar sobre

restrições de velocidade e deslocamento máximo da pista do equipamento. (HO; CHEN, 2009)

Assim, os parâmetros adotados por Ho e Chen (2009) na construção do modelo da sua máquina de CPM/CAM, foram baseados, em um deslocamento máximo da plataforma de 0,5m (X_{max}), uma força máxima do usuário no valor de 450N, medida por um sensor de força (F_{max}). Desse modo, o valor de $\zeta = 0,8$ (sistema subamortecido) e $\omega_n = 0,05rad/s$, foram escolhidos de modo a evitar oscilações e sobressinais, bem como evitar que a plataforma se desloque rapidamente.

Neste contexto, para encontrar os valores de M-b-K valor é necessário rearranjar o denominador da equação 4.4,

$$M\ddot{x} + b\dot{x} + Kx = M \left(\ddot{x} + \frac{b}{M}\dot{x} + \frac{K}{M}x \right) \therefore M(\ddot{x} + 2\zeta\omega_n\dot{x} + \omega_n^2x) \quad (4.5)$$

Assim, o parâmetro K é:

$$K = \frac{F_{max}}{X_{max}} = \frac{450}{0,5} = 900 \therefore \omega_n^2 = 30. \quad (4.6)$$

Analogamente, o parâmetro M , é

$$\omega_n^2 = 0,05^2 = \frac{K}{M} = \frac{900}{M} \therefore M = \frac{900}{0,0025} = 360.000 \quad (4.7)$$

Da mesma forma, o parâmetro b é

$$2\zeta\omega_n = 2 \times 0,8 \times 0,05 = \frac{b}{360.000} \therefore b = 28.000 \quad (4.8)$$

Portanto, o modelo da máquina de CPM/CAM, utilizada por Ho e Chen (2009), desconsiderando o atrito $csgn(\dot{x})$ é,

$$360.000\ddot{x} + 28.000\dot{x} + 900x = F \quad (4.9)$$

Como a iteração paciente-dispositivo é dinâmica, as limitações que definem os parâmetros m-b-k do modelo da máquina de CPM/CAM podem mudar, conseqüentemente os valores dos parâmetros do modelo de segunda ordem apresentado na eq.4.3, deverão ser recalculados.

4.6.2 Critério de estabilidade de Nyquist

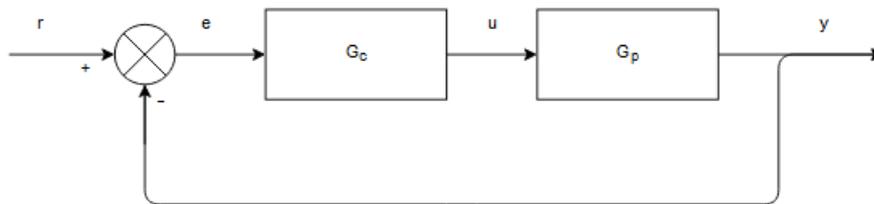
A robustez de qualquer sistema de controle em malha fechada é uma característica muito importante, a ser avaliada, logo um sistema de controle para uma máquina

de CPM/CAM robusto, proporciona uma maior margem as incertezas do modelo do processo (devido não-linearidades e aproximações) e uma menor variação da saída do controlador (TORGA, 2018). Nesse contexto, a estabilidade ou robustez do processo (interação paciente-máquina de CPM/CAM) pode ser avaliada através do diagrama de Nyquist.

O critério de Nyquist estabelece uma relação entre a estabilidade de um sistema de controle em malha fechada, com a resposta em frequência e a posição de seus pólos, em malha aberta. Dessa forma, por meio do critério de Nyquist é possível saber quais pólos do sistema em malha fechada estão no semiplano direito e, conseqüentemente, avaliar a estabilidade desse sistema (TORGA, 2018), (NISE, 2007).

A figura 14 apresenta um sistema em malha fechada com realimentação simples, em que r representa a realimentação, e o erro ($r - y$), G_c , o controlador com sua respectiva saída u (lei de controle), G_p , o modelo do mecanismo CPM/CAM (processo) e por fim, y representa a variável de saída a ser mensurada. (ÅSTRÖM; WITTENMARK, 2013),

Figura 14 – Malha de controle com *feedback* simples



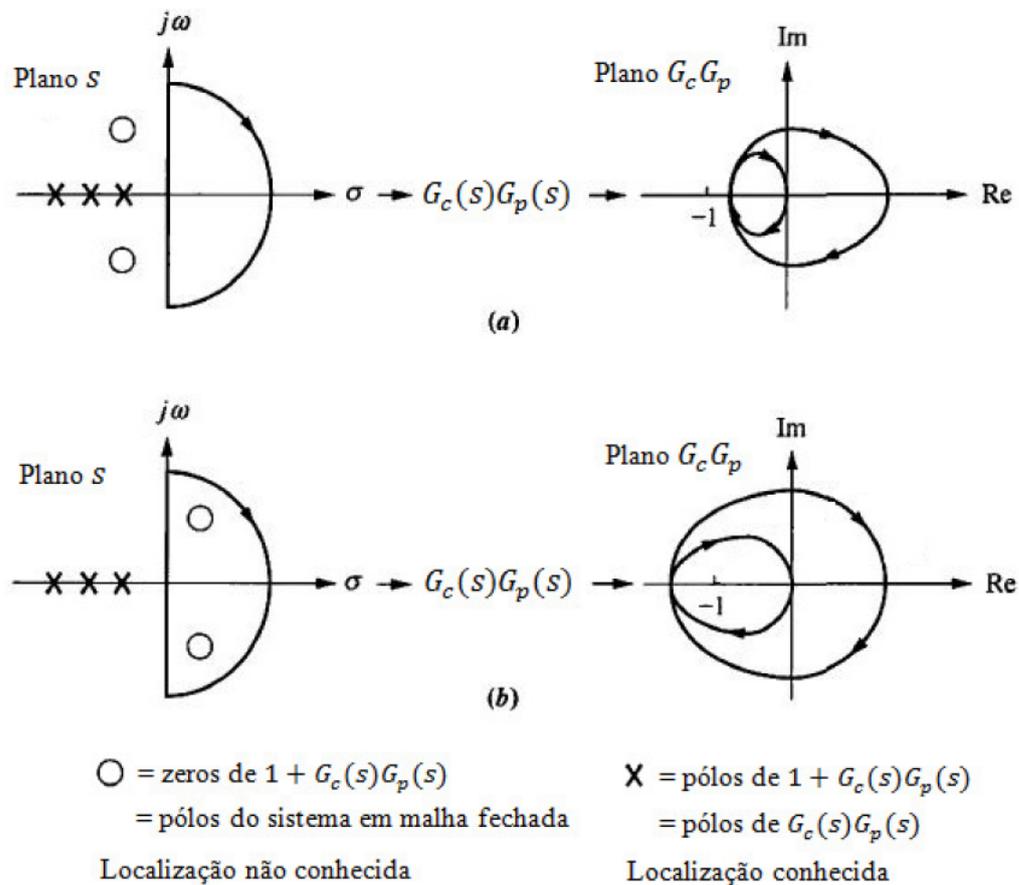
Fonte: Adaptado de (TORGA, 2018)

Para analisar a estabilidade de um sistema de controle em malha fechada através do critério de Nyquist é necessário conhecer a equação característica do sistema, apresentado na eq.4.10:

$$Q(s) = 1 + G_c(s)G_p(s) \quad (4.10)$$

Segundo Torga, "(...) os polos da equação característica do sistema são os mesmos polos do sistema $T(s)$ em malha fechada e são os mesmos polos de $G_c(s)G_p(s)$ em malha aberta (...)" (TORGA, 2018). Dessa forma, a estabilidade do sistema de controle depende da localização das raízes (zeros) da equação característica, onde todos devem estar no semiplano s da esquerda. A figura 15, mostra exemplos de localização dos polos e zeros em malha fechada de um sistema estável e instável no diagrama de Nyquist, também conhecido como mapeamento de polos e zeros.

Figura 15 – Exemplos do critério de Nyquist:



(a) Sistema estável e (b) Sistema instável. Fonte: (TORGA, 2018)

O mapeamento de polos e zeros de Nyquist mostrado na figura 15, da equação 4.11, origina-se do teorema de Cauchy, em que, N determina o número de circunscrições da origem (sentido horário), Z é o número de polos em malha fechada no semiplano s da direita e P representa o número de polos em malha aberta no mesmo semiplano (TORGA, 2018).

$$N = Z - P \quad (4.11)$$

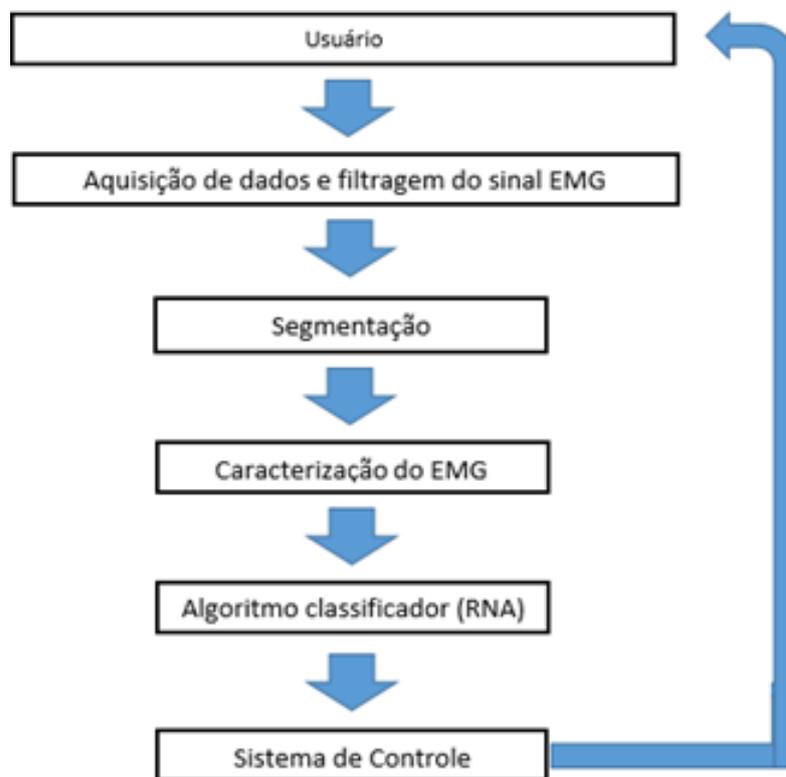
Consequentemente, o critério de estabilidade de Nyquist é avaliado por meio da equação 4.12. O sistema será estável em malha fechada se e somente se $Z = 0$; qualquer outro valor diferente de $Z = 0$ implicará em um sistema instável.

$$N + P = 0 \quad (4.12)$$

4.7 Sistema genérico de identificação e controle baseado em EMG

Uma das abordagens adotadas atualmente para a criação de sistemas inteligentes capazes de utilizar a eletromiografia como base para sistemas de controle pode ser observada no diagrama de blocos da figura 16. Nesse fluxograma é possível observar, de forma condensada, as etapas que vão desde a coleta do EMG até o sistema de controle final (AMRANI et al., 2017).

Figura 16 – Diagrama de blocos simplificado de um sistema de classificação de EMG



Fonte: Adaptado de (AMRANI et al., 2017)

1. Aquisição e filtragem do EMG: Nesta etapa os sinais são coletados por meio do posicionamento de eletrodos no paciente. O EMG é capturado, amplificado e filtrado em um eletromiógrafo.
2. Segmentação: Nesta etapa, o conjunto de dados obtidos, passa por um janelamento, ou seja, é selecionado uma parte do EMG. Neste processo existem vários tipos de janela que podem ser utilizadas. A escolha de uma janela adequada é importante a fim de evitar efeitos indesejados como o *sync* e o *overlapping*.
3. Caracterização do EMG: Nesta etapa são escolhidos parâmetros que caracterizam o sinal e que servem de base decisória para a RNA. Características desejáveis em um sinal de EMG, podem ser por exemplo, média absoluta, *zero – crossing*, desvio padrão, energia, dentre outros.

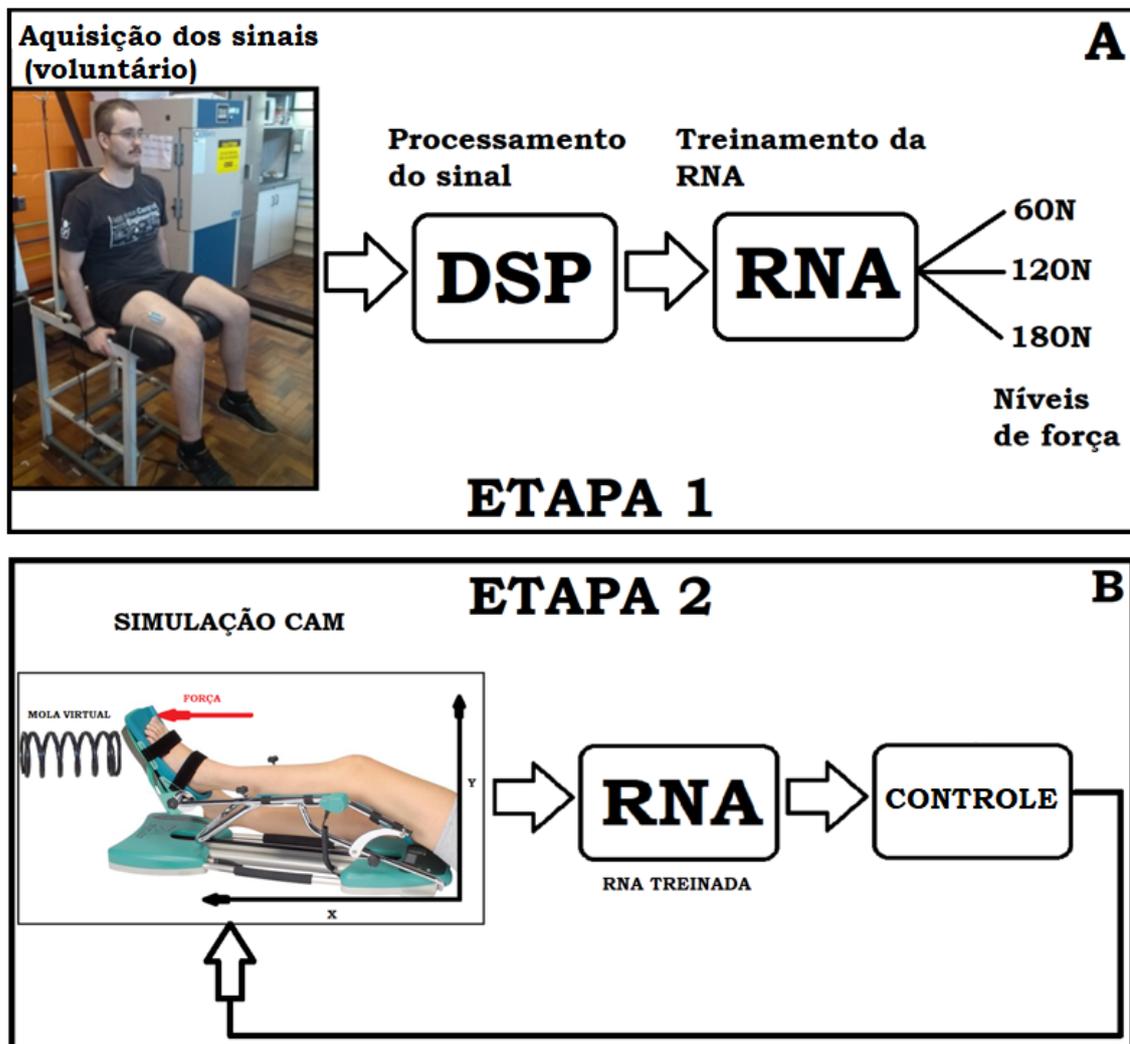
4. Algoritmo Classificador: O algoritmo classificador pode ser uma RNA, que pode ser arranjada de várias formas. As formas mais comuns são no formato *multilayer feedforward*. O método de treinamento supervisionado mais adotado para esse formato é o *backpropagation*.
5. Sistema de Controle: O sistema de controle utiliza os dados fornecidos pelo algoritmo classificador. Os dados que são utilizados pelo controlador variam de acordo com o problema.

5 A TÉCNICA PROPOSTA

A proposta deste trabalho surgiu das necessidade de implementar um sistema de controle em malha fechada para máquinas de CPM (do termo em inglês, *Continuous Active Movement*), com base em sinais eletromiográficos do próprio usuário, através da criação de um *feedback* de realimentação para um sistema de controle, possibilitando que criar o Movimento Ativo Contínuo (CAM, do inglês: *Continuous Active Movement*).

Nesse contexto, o trabalho foi dividido em duas etapas: A etapa 1 - envolve a coleta dos sinais eletromiográficos dos voluntários e o treinamento da rede neural (figura 17A). Etapa 2 - Na segunda, é realizada a simulação do sistema CAM completo em Matlab, já com a RNA baseada no reconhecimento de padrões de EMG treinada (figura 17B).

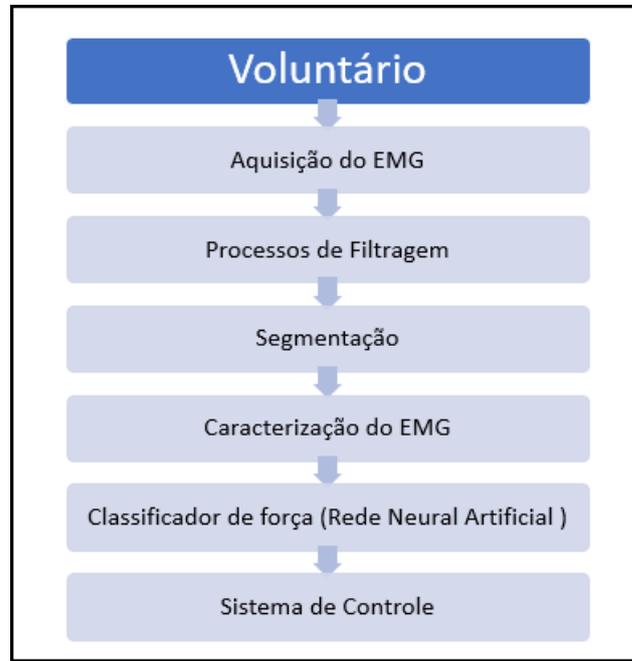
Figura 17 – Etapas da técnica proposta



A-Aquisição de dados; B-Simulação do sistema CAM; Fonte: Elaborado pelo autor

O diagrama geral desse estudo consiste em seis etapas: aquisição de dados, segmentação, caracterização do sinal, classificação e sistema de controle, podendo ser observado na figura 18.

Figura 18 – Fluxograma de Funcionamento da Técnica proposta



Fonte: Elaborado pelo autor

5.1 Aquisição dos sinais eletromiográficos no voluntário

Nesse estudo, ao todo, foram selecionados 10 voluntários do sexo masculino, com idade entre 18 e 30 anos, sem diagnóstico conhecido de doenças neurológicas ou osteomio-articulares, que aceitaram participar do estudo, após a leitura do termo de consentimento livre e esclarecido (TCLE – Apêndice A).

Foram excluídos do estudo os indivíduos que referiram qualquer problema de saúde que impedisse a realização de exercício de extensão de joelho por motivo de dor, limitação de movimento ou qualquer contraindicação para realizar o teste de força máxima de extensão de joelho (lesão de menisco, ligamentos, cápsula articular, inflamação, traumatismo prévio nos últimos 30 dias, etc.). Esta pesquisa foi aprovada em 30 de agosto de 2019 pelo Comitê de Ética da Pontifícia Universidade Católica do Rio Grande do Sul (CAEE 18140819.0.0000.5336), protocolo 3544339.

A tabela 2, mostra os dados demográficos (idade, massa etc.) do grupo de voluntários utilizados neste estudo.

Tabela 2 – Dados demográficos do grupo

Voluntários	Idade (anos)	Massa (kg)	Altura (m)	IMC
1	25	80.0000	1.90	22.1607
2	24	100.0000	1.92	27.1267
3	26	65.0000	1.65	23.8751
4	23	81.0000	1.85	23.6669
5	21	82.0000	1.72	27.7177
6	20	68.0000	1.73	22.7204
7	22	80.0000	1.69	28.0102
8	23	92.0000	1.80	28.3951
9	23	102.0000	1.82	30.7934
10	24	95.0000	1.74	31.3780
Média geral	23.1	84.5	1.78	26.58

Fonte: Elaborado pelo Autor

Pode-se observar que a idade média do grupo é de 23 anos, altura média de 1.78 metros e com valor de IMC médio 26.58.

5.1.1 Desenho experimental

O sinal eletromiográfico utilizado para a avaliação do movimento de extensão do joelho neste trabalho, foi adquirido através da eletromiografia de superfície do músculo vasto lateral, em dois protocolos de exercícios: exercício incremental e teste de força máxima (1RM).

5.1.2 Exercício experimental

Para simular uma atividade muscular do sinal EMG mais próxima de uma máquina de CPM (uma vez que uma máquina de CPM não estava disponível), os voluntários foram posicionados em um equipamento (cadeira Flexora-Extensora) que permite a aplicação diferentes módulos de carga de trabalho de forma a resistir o movimento de extensão de joelho, como mostrado na figura 19. Em A é possível observar o membro inferior direito posicionado no aparelho em estado de relaxamento. Em B verifica-se a realização do movimento de extensão de joelho elevando a carga pré-estipulada na cadeira Flexora-Extensora.

Figura 19 – Equipamento utilizado na coleta de dados(Flexora-Extensora)



A-Estado relaxado; B-Estado Contraído relaxado; Fonte: Elaborado pelo autor

Após o posicionamento do voluntário foram realizados 10 movimentos de extensão no joelho dominante, de forma lenta (aproximadamente 5" por movimento) com cada uma das seguintes cargas de 60, 120, 180 N (Newtons), totalizando trezentos sinais. As cargas foram estipuladas de acordo com a capacidade dos voluntários.

5.1.3 Teste de força máxima (1RM)

O teste foi realizado no equipamento de extensão de joelho (cadeira Flexora-Extensora) da figura 19, de acordo com os seguintes passos:

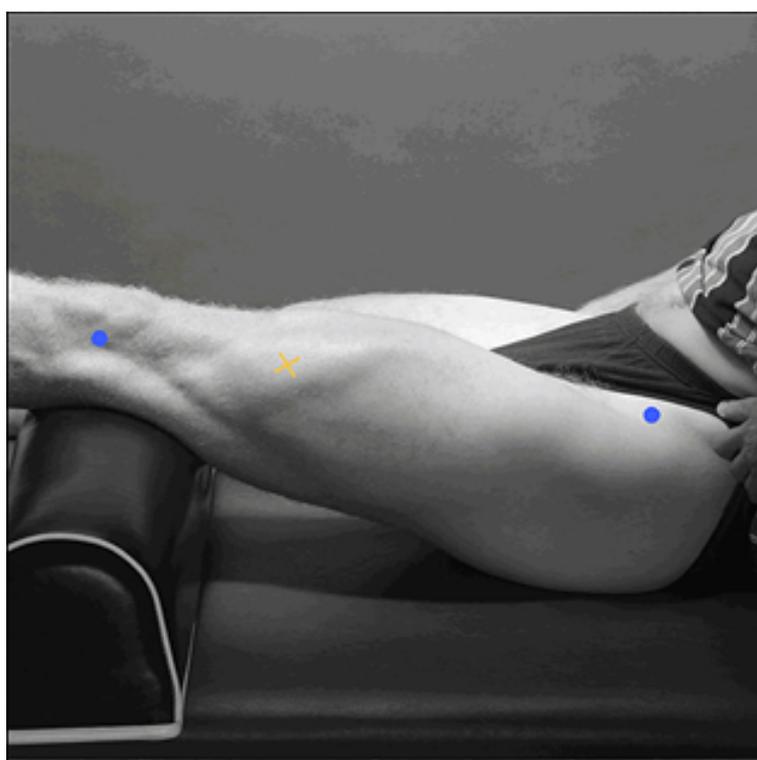
1. Aquecimento com cargas leves (10 repetições do movimento de extensão do joelho);
2. Aguardar 1 minuto de recuperação;
3. Estimar uma carga que permita ao voluntário completar até 5 repetições e realizar as repetições;
4. Aguardar 2 minutos de recuperação;
5. Estimar uma carga que permita ao voluntário completar até 3 repetições e realizar as repetições;

6. Aguardar 3 minutos de recuperação;
7. Incrementar de 5 a 10 % na carga utilizada na última série e solicitar uma repetição (1RM);
8. Em caso de sucesso, realizar intervalo de 4 minutos, aumentar 10 % da carga da tentativa anterior;
9. Continuar incrementando a carga até que o voluntário não consiga realizar a carga com perfeição.
10. É recomendado que a 1RM seja encontrada em até 5 tentativas.

5.1.4 Posicionamento dos eletrodos para a coleta da eletromiografia

As recomendações da Sociedade Internacional de Eletromiografia e Cinesiologia foram utilizadas para preparação do sujeito e posicionamento dos eletrodos (MERLETTI, 2000), (MERLETTI; HERMENS, 2000) O local da aplicação dos eletrodos para análise da atividade elétrica do músculo vasto lateral, segundo o protocolo da SENIAM (MERLETTI, 2000), é aos 2/3 distal de uma linha que liga a espinha íliaca ântero-superior e a face lateral da patela, mantendo uma distância de 20mm entre eles, conforme figura 20.

Figura 20 – Posicionamento de eletrodos no músculo vasto lateral, segundo a literatura



Fonte: (MERLETTI, 2000)

O eletrodo de referência foi posicionado no maléolo lateral, cujo inicialmente foi realizada a preparação da pele no local de aplicação dos eletrodos, conforme as seguintes instruções:

1. Tricotomia dos locais onde serão colocados os eletrodos;
2. Limpeza da pele por abrasão;
3. Limpeza com álcool;
4. Aguardar, no mínimo, 5 minutos entre a colocação dos eletrodos e a avaliação;

O registro eletromiográfico foi realizado durante a execução do exercício incremental e da 1RM por meio do eletromiógrafo (equipamento de coleta de sinais eletromiográficos) modelo Miotec-Miotool - 200/400, que possui frequência de amostragem ajustada em 2000Hz e precisão de 14 bits (conversor digital), segundo o fabricante (MIOTEC, 2008), conforme figura 21.

Figura 21 – Eletromiógrafo utilizado na coleta de dados



Fonte: Elaborado pelo autor

Associado ao equipamento, foi utilizado um par de eletrodos de superfície autoadesivos e descartáveis (compostos de prata-cloreto de prata - Ag-AgCl) por usuário, como mostrado na figura 22.

Figura 22 – Eletrodos de superfície autoadesivos



Fonte: Elaborado pelo autor

Para medir a força realizada pelo usuário, seja na primeira etapa (exercício experimental) como na segunda etapa (1RM-força máxima), foi utilizado um dinamômetro (figura 23) acoplado a cadeira Flexora-Extensora. O dinamômetro marca Bestfer tem sensibilidade de 1kg e capacidade de carga para até 100kg.

Figura 23 – Dinamômetro



Fonte: Elaborado pelo autor

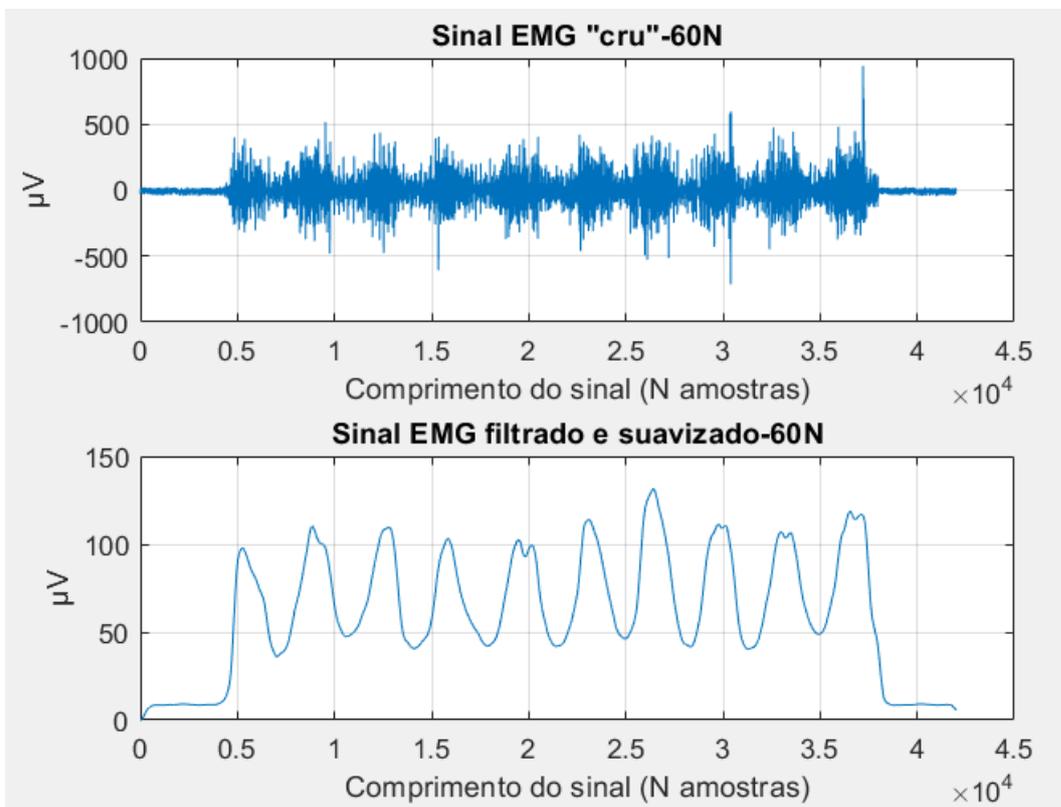
5.2 Filtragem e segmentação dos sinais eletromiográficos

5.2.1 Processos de filtragem

O primeiro passo no processo de filtragem foi remover qualquer deslocamento que os sinais brutos pudessem ter, seguido pela retificação de onda completa. Para sinais EMG de superfície, a amplitude está em uma faixa entre [0 a 10 mV] e a faixa de frequência é restrita de [10 a 500 Hz], com maior potência de frequência entre [10 a 250 Hz] (NAZMI et al., 2016). Portanto, um filtro de banda de 20 a 500Hz e um filtro de 60Hz foram aplicados nos processos de filtragem, evitando ruídos e reunindo apenas as informações relevantes do sinal sEMG (AMRANI et al., 2017).

O sinal filtrado foi suavizado com um filtro de média móvel com uma janela de 300ms de comprimento, para prepará-lo para encontrar os picos de contração na etapa de segmentação (KONRAD, 2005). A figura 24 mostra o sinal "cru", ou seja, sem processamento algum após ter sido coletado, em comparação aos processos de filtragem e suavização (preparação pré segmentação).

Figura 24 – Sinal EMG "cru" vs filtrado e suavizado



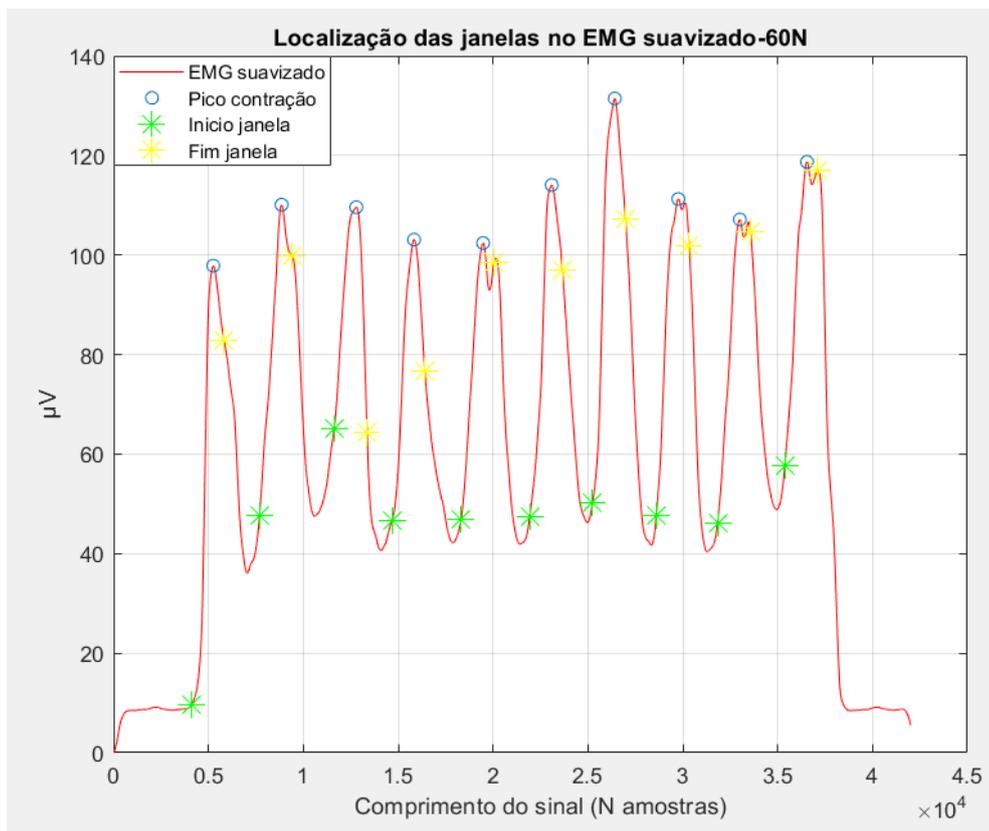
Fonte: Elaborado pelo autor

5.2.2 Segmentação

Existem várias maneiras de segmentar um sinal EMG para aplicações online; os métodos de janelas sobrepostas e adjacentes são alguns exemplos (AMRANI et al., 2017). No entanto, neste trabalho, adotamos a abordagem *offline*, que utiliza os sinais já coletados previamente para simular o funcionamento do sistema CAM. Portanto, usamos uma técnica que utiliza um valor limite (*threshold*) baseado no valor médio absoluto do sinal eletromiográfico suavizado, a fim de encontrar seus principais picos.

As localizações dos picos principais encontradas no sinal suavizado (Figura 25) serviram como base para encontrar o início e o final do período de contração, assim um comprimento padrão da janela pode ser estabelecido e utilizado para segmentar o sinal de EMG filtrado (Figura 26).

Figura 25 – Processo de segmentação

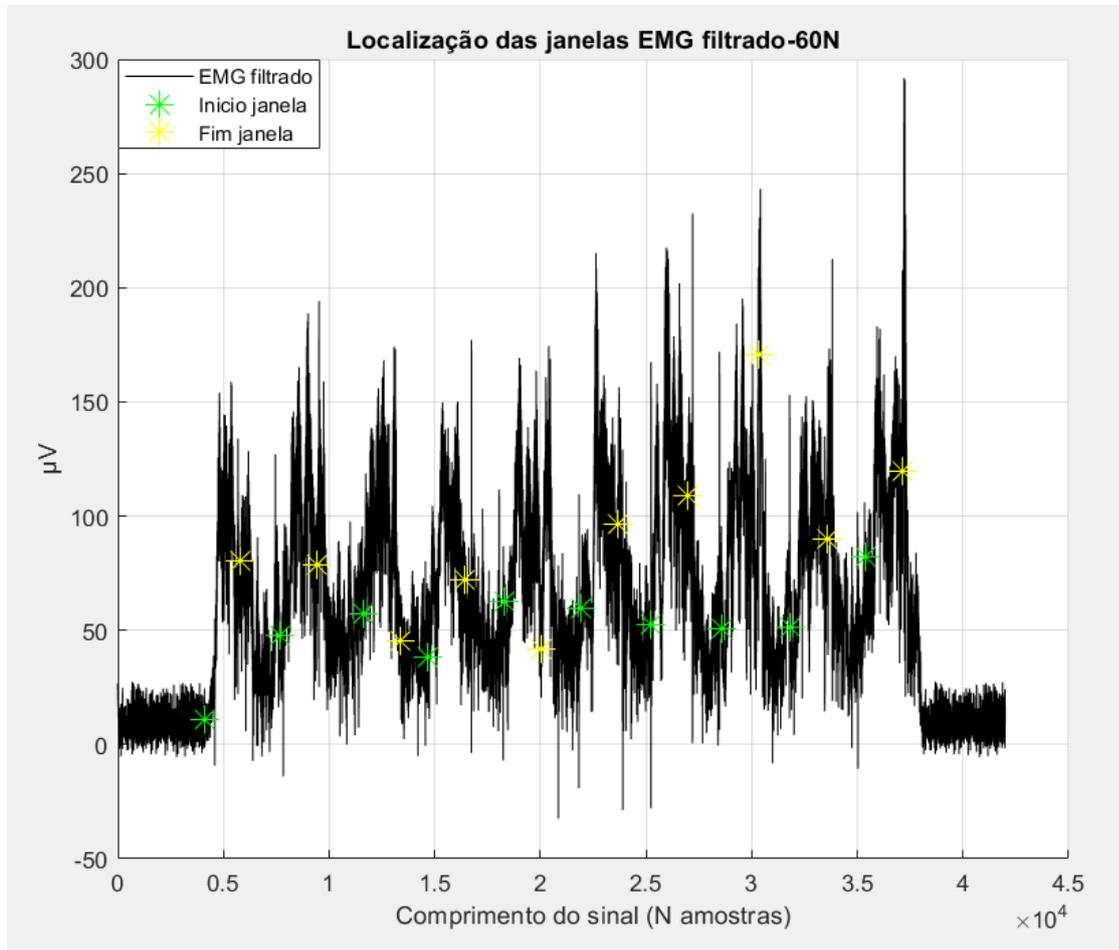


Fonte: Elaborado pelo autor

A figura 26 mostra os resultados da abordagem adotada neste trabalho, em que, os principais picos são os marcadores azuis, seguidos pelo verde (início da janela) e amarelo (final da janela). Uma vez que nossa aplicação é uma simulação *offline* (logo, o comprimento da janela, seu início e seu final estavam disponíveis), uma janela Gaussiana com comprimento padrão foi escolhida no *Signal Processing Toolbox* do *software* Matlab para

ser aplicada nos sinais de EMG filtrados, assim segmentando cada contração (Figura 26).

Figura 26 – Localizações das janelas após segmentação



Fonte: Elaborado pelo autor

5.2.3 Caracterização do EMG

O processo de caracterização significa extrair os principais atributos de um EMG necessários para estabelecer um padrão de reconhecimento. Esse processo pode ser feito no domínio do tempo (DT), no domínio da frequência (DF) ou em ambos. Por exemplo, o valor absoluto médio (VAM), o comprimento da forma de onda (WL, do inglês: *Waveform length*) e o cruzamento de zero (CZ) são os atributos do *DT* mais utilizados (AMRANI et al., 2017). Por outro lado, outros estudos adotam características no domínio frequência, como por exemplo, densidade do espectro de potência (PSD, do termo em inglês *Power Spectrum Density*) e frequência média (FM) como atributos para caracterizar um sinal EMG (NAZMI et al., 2016).

A escolha correta dessas características do sinal depende da quantidade de dados necessários para criar o padrão utilizado no processo de identificação e classificação dos sinais e, ao mesmo tempo, deve-se manter a complexidade computacional baixa.

O primeiro atributo chave calculado neste estudo é a energia do pulso (contração) por janela (primeira característica) de acordo com a Eq.5.1 (domínio em tempo discreto), considerando cada sinal de EMG segmentado com comprimento finito, absoluto e somável.

$$E = \sum_{n=N1}^{N2} |x[n]|^2 \quad (5.1)$$

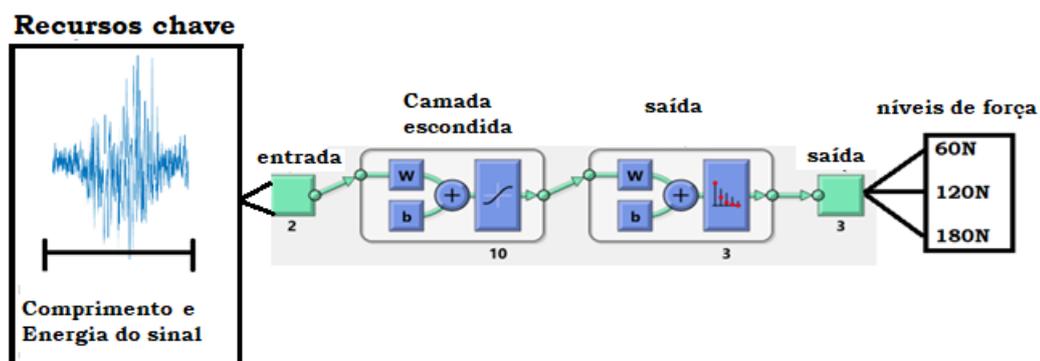
Depois disso, todos os 300 valores de energia foram normalizados pela força máxima do voluntário, dessa forma, é possível estabelecer um padrão de energia para cada contração adquirida e associar ao seu nível de força (KONRAD, 2005) O segundo atributo extraído usado para caracterizar o sinal EMG foi o comprimento da forma de onda (WL, do termo em inglês *Waveform Length*) (Eq.5.2), os comprimentos das janelas foram normalizados pelo valor da maior janela, onde N é o tamanho do segmento e $x[n]$ é o sinal da janela (NAZMI et al., 2016).

$$WL = \sum_{n=1}^{N-1} |x[n+1] - x_n| \quad (5.2)$$

5.3 Classificador de força (rede neural artificial)

A RNFFMC projetada (Figura 27) consiste em três camadas com seus respectivos neurônios, entrada com 2 neurônios, camada oculta com 10 e a camada de saída com 3. A arquitetura RNFFMC foi implementada usando a ferramenta de reconhecimento de padrões da *Neural Network Toolbox*, fornecida pelo software MATLAB. Os valores de energia calculados são associados aos seus respectivos WL e utilizados como entrada para a RNA. A saída desejada para a rede neural, são três níveis de força cujos os sinais de EMG de foram coletados (60, 120 e 180N).

Figura 27 – Classificador de forças baseado em rede neural



Fonte: Elaborado pelo autor

Os 300 valores de entrada (energia) são divididos em 210 amostras (70%) para treinamento, 45 (15%) para validação e as outras 45 amostras (15%) para testar a RNA. O algoritmo de aprendizado utilizado para treinar a rede foi o SCG (do termo em inglês, *Scaled Conjugate Gradient* gradiente conjugado em escala) e o método de aprendizado supervisionado adotado foi o *backpropagation* (AMRANI et al., 2017), (YOUSEFI; HAMILTON-WRIGHT, 2014).

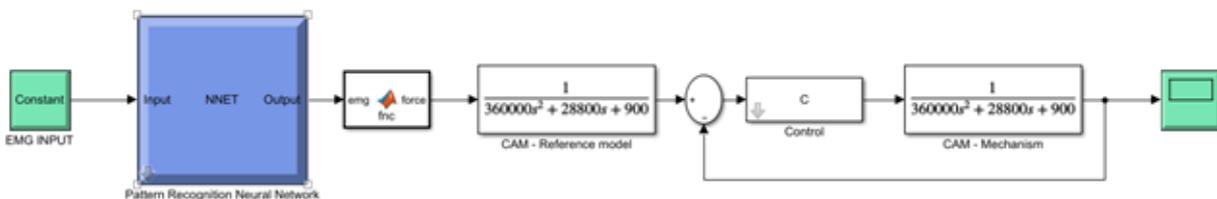
5.4 Sistema de controle

A simulação do sistema de controle em malha fechada da máquina de CPM/CAM, é baseada no trabalho de Ho e Chen (2009), em que eles utilizaram um modelo de referência (equação 4.9) para alimentar uma estratégia adaptativa, com um controlador em modo deslizante, associado a uma FNN (*fuzzy-neural network*). Nesse contexto, rearranjamos a equação 4.9 no domínio frequência complexa (Laplace) e obtemos a eq.5.3.

$$G_p(s) = \frac{1}{360.000s^2 + 28.000s + 900} \quad (5.3)$$

Neste trabalho utilizamos o mesmo modelo de referência (4.9) já validado por Ho e Chen, como base para o projeto de um novo controlador, cuja entrada são dados de força classificados pela RNA. A estrutura em malha fechada que utiliza dados eletromiográficos previamente coletados e caracteriza-os criando um *feedback* para o sistema de controle é apresentada na figura 28.

Figura 28 – Sistema de Controle da Máquina de CPM



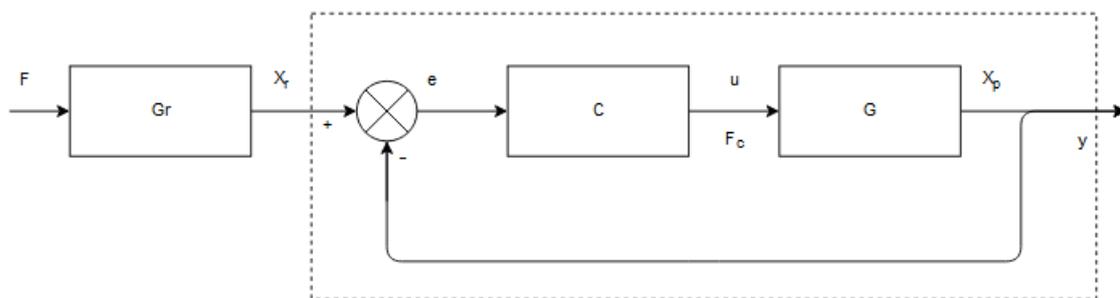
Fonte: Elaborado pelo autor

Com base na equação 5.3, projetamos um compensador utilizando a ferramenta de *rltool* da biblioteca *Control System Toolbox* do *software* Matlab. Projetamos o controlador de forma a apresentar os seguintes requisitos:

- Resposta suave;
- Sobressinal menor que 5%;
- Erro de posição menor que 1%;
- Resposta lenta;
- Estável;

A avaliação de estabilidade do sistema de controle em malha fechada proposto para o modelo da máquina de CPM/CAM, foi realizada no Matlab através do diagrama de Nyquist e verificação do lugar geométrico das raízes. O diagrama de blocos da figura 29 representa simplificada a malha de controle interna cuja estabilidade foi avaliada.

Figura 29 – Diagrama de blocos do sistema de controle



Fonte: Elaborado pelo autor

6 VALIDAÇÃO

Como validação para a rede neural artificial, foi testada a sua acurácia por meio de uma matriz de confusão (*Confusion matrix*). O classificador baseado em RNA proposto neste trabalho foi comparado em termos de acurácia com outros trabalhos previamente apresentados no estado da arte (Capítulo 2). Como forma de validação do sistema de controle, foram realizados testes de estabilidade do sistema.

A tabela 3 mostra os resultados do processo de extração dos atributos dos sinais eletromiográficos, onde, para cada voluntário, calculamos o valor médio da energia por contração, em cada nível de força (60N, 120N e 180N). Depois disso, calculamos o valor médio da energia correspondente ao seu nível de força (de cada voluntário), bem como o desvio padrão para cada classe de força. Por exemplo, o valor médio da energia relacionado a uma contração de 60N é 0,0267J com desvio padrão da média 1,77%.

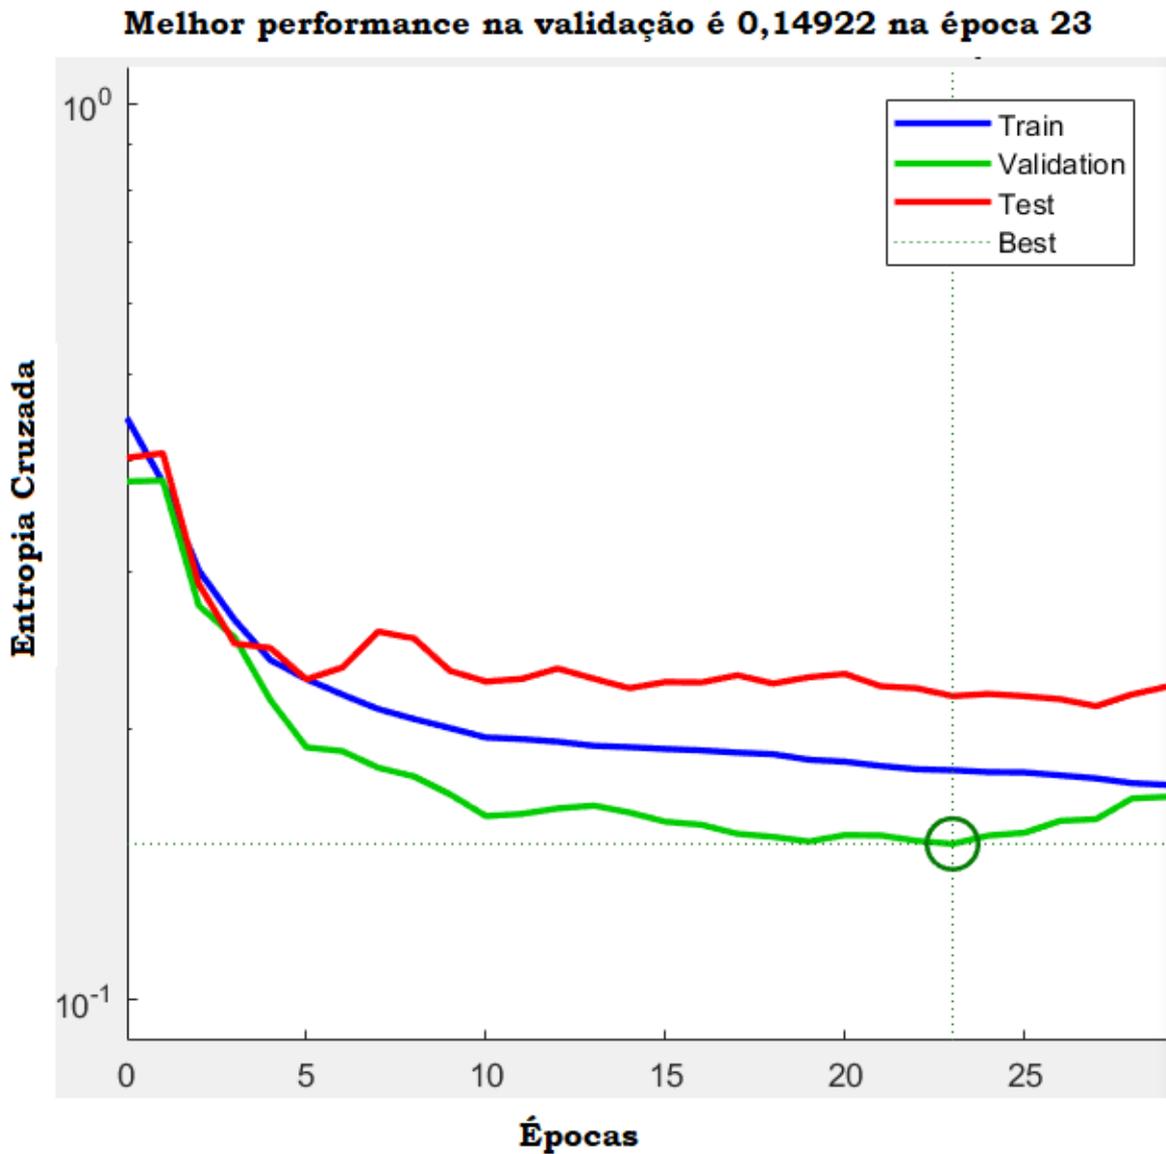
Tabela 3 – Energia media por contração vs níveis de força

Voluntários	E. média-60N (J)	Desv.padrão	E. média-120N (J)	Desv.padrão	E. média-180N (J)	Desv.padrão
1	0.025	0.0043	0.0391	0.0063	0.0704	0.0181
2	0.0181	0.0040	0.045	0.0068	0.0647	0.0142
3	0.0246	0.0056	0.0419	0.0089	0.0747	0.0076
4	0.0158	0.0035	0.0362	0.0129	0.0365	0.0089
5	0.0191	0.0028	0.0464	0.0092	0.1052	0.0407
6	0.0573	0.0091	0.0613	0.0170	0.1243	0.0371
7	0.0236	0.0088	0.0493	0.0117	0.0804	0.0158
8	0.0283	0.0048	0.0355	0.0077	0.074	0.0123
9	0.0055	0.0011	0.0401	0.0195	0.12	0.0283
10	0.0499	0.0273	0.0495	0.0200	0.1219	0.0314
Média geral	0.0267		0.0444		0.0872	
Desvio padrão da média	1.77%		1.44%		3.63%	

Fonte: Elaborado pelo Autor

A figura 30 mostra as diminuições no valor da entropia cruzada, o que significa a melhoria da classificação durante as etapas de treinamento e validação. O valor 0,14922 é o valor mínimo na entropia cruzada encontrada na 23ª época (iteração) que valida o classificador de força (RNA) com base na EMG do paciente.

Figura 30 – Entropia Cruzada



Fonte: Elaborado pelo Autor

Por outro lado, a Figura 31 mostra a matriz de confusão, onde é possível ver a precisão do algoritmo classificador (RNA). Através da matriz de confusão é possível ver a porcentagem total de sinais EMGs correta e incorretamente classificadas em níveis de força. O número de classificações verdadeiras é marcado em verde, enquanto os falsos positivos estão em vermelho, no geral a RNA classificou 81,0% (erro = 19%) de 300 amostras de EMG corretamente.

Figura 31 – Matriz de confusão

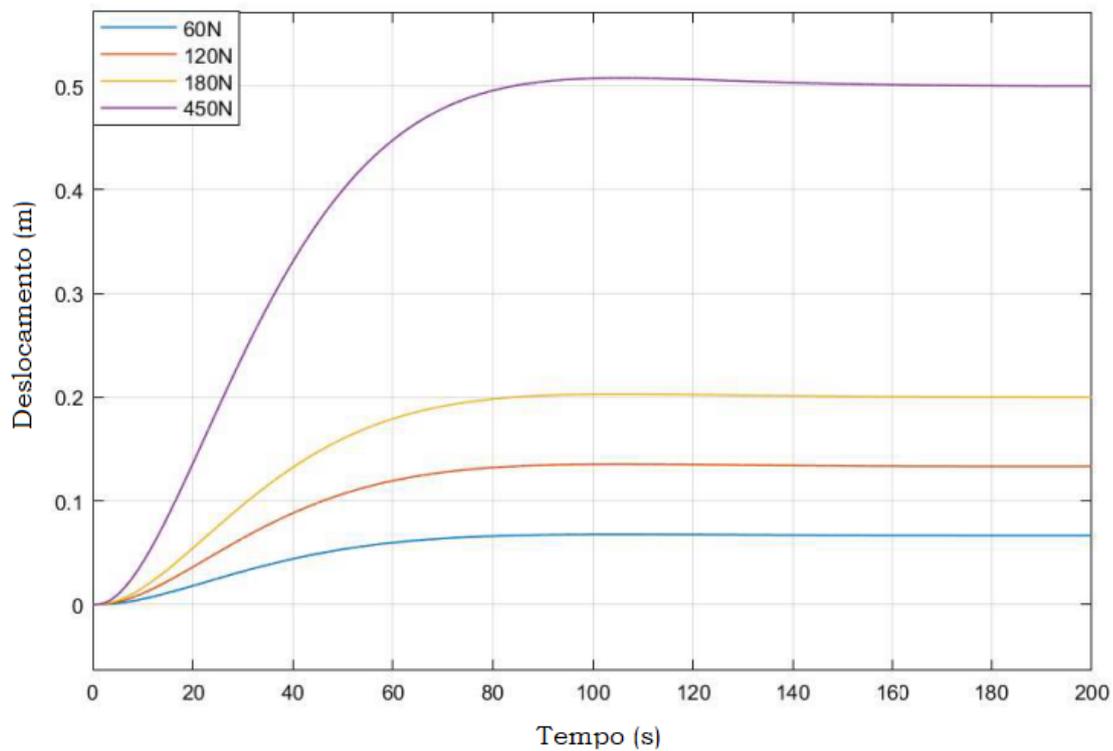
		60N	120N	180N	
CLASSES DE SAÍDA	1	84 28.0%	12 4.0%	2 0.7%	85.7% 14.3%
	2	11 3.7%	78 26.0%	17 5.7%	73.6% 26.4%
	3	5 1.7%	10 3.3%	81 27.0%	84.4% 15.6%
		84.0% 16.0%	78.0% 22.0%	81.0% 19.0%	81.0% 19.0%
		1	2	3	CLASSES ALVO

Fonte: Elaborado pelo Autor

O esforço computacional do classificador e seu desempenho são quantificados através da medição do tempo de execução. Nosso algoritmo é capaz de processar as 100 amostras através de etapas de filtragem, segmentação, caracterização e classificação, em 620ms (milissegundos), resultando em 62ms por pulso (contração).

A figura 32 mostra as respostas de circuito em malha fechada do sistema CPM / CAM para diferentes níveis de força. Os valores de 60N, 120N, 180N foram obtidos do classificador sEMG e aplicados ao modelo de mecanismo. O valor de 450N é apenas uma simulação do valor máximo de força possível (apenas para referência) para o mecanismo. Nós projetamos o controlador (compensador) para fornecer uma resposta suave e sem erros de posição e simular uma terapia CPM/CAM de velocidade normal realizada por um paciente (cerca de 100 segundos). Os resultados da simulação da abordagem de controle com base na eletromiografia são mostrados na figura32.

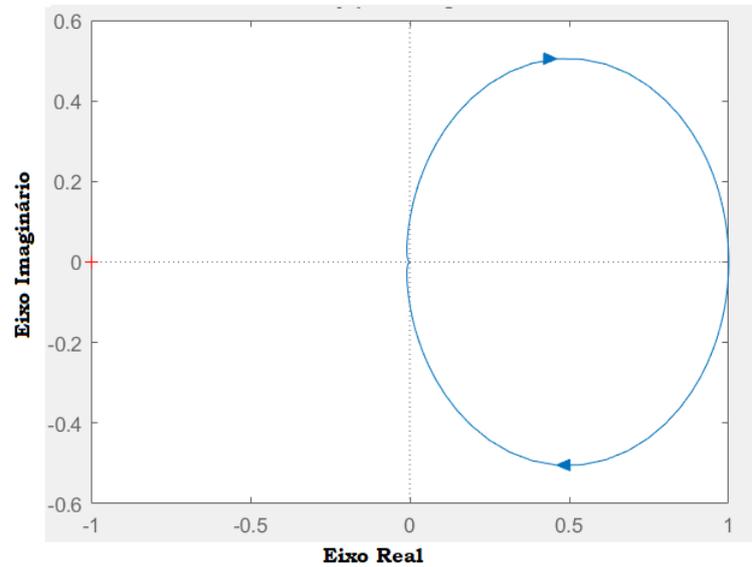
Figura 32 – Saída do sistema em malha fechada



Fonte: Elaborado pelo Autor

A validação do sistema de controle proposto neste trabalho envolveu a estabilidade por Nyquist. A figura 33 mostra o diagrama de Nyquist para o sistema de controle da máquina de CPM/CAM em malha fechada.

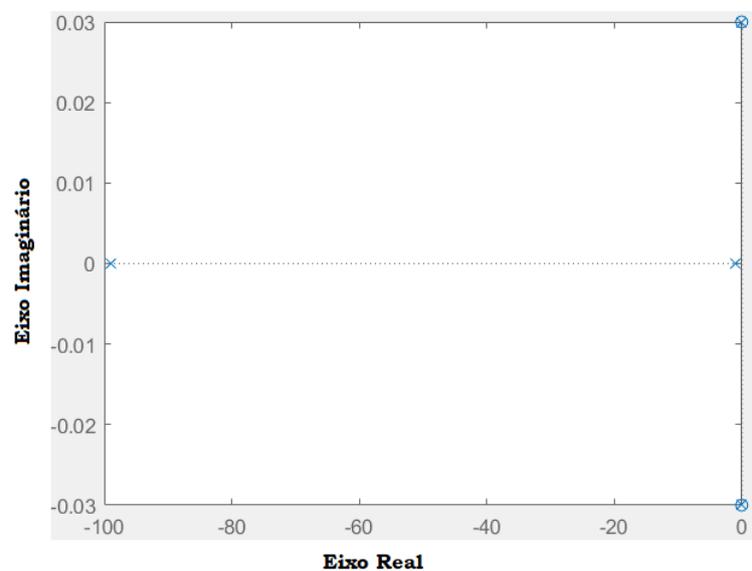
Figura 33 – Diagrama de Nyquist do sistema de controle em malha fechada



Fonte: Elaborado pelo autor

Além da avaliação da estabilidade pelo critério de Nyquist, como uma segunda validação, foi realizada a verificação da estabilidade pelo método de localização das raízes do sistema em malha fechada. A figura 34 mostra a localização dos polos zeros do sistema de controle em malha fechada proposto.

Figura 34 – Raízes do sistema de controle em malha fechada



Fonte: Elaborado pelo autor

7 AVALIAÇÃO

Este trabalho apresentou uma nova abordagem (baseada em EMGs), considerando as estratégias de controle de última geração adotadas em máquinas de CPM / CAM de joelho. A abordagem de controle baseada no *biofeedback* do paciente traz inovação ao campo em relação às máquinas de CPM / CAM de joelho (HO; CHEN, 2006), (HO; CHEN, 2008), (HO; CHEN, 2009). Da mesma forma, nossa simulação mostrou ótimos resultados no tempo de processamento de EMGs (62 milissegundos) se comparado a um trabalho semelhante proposto por Amrani et. al (2017), que atingiu 300 milissegundos. Além disso, usamos apenas dois atributos principais extraídos da EMG do paciente para caracterizar e classificar o sinal em um nível de força, se comparado a trabalhos semelhantes que usaram pelo menos quatro (CUI et al., 2017), (AMRANI et al., 2017).

Em relação ao classificador (MFFNN treinado com algoritmo *backpropagation*), nosso estudo apresentou 81% de precisão no processo de classificação EMG, um bom resultado considerando o uso de dois atributos característicos, mas 11% menos preciso se comparado ao Amrani et. al (2017), que alcançou 95% de precisão usando quatro atributos.

A abordagem de controle proposta neste trabalho utilizou um modelo validado proposto por Ho et. al (2009) para simular nosso estudo. O modelo do mecanismo CPM/CAM tinha duas restrições: deslocamento máximo (0,5 m) quando estimulado com 450N (força máxima permitida pelo paciente). Por isso, comparamos a resposta de 450N como um valor de referência com nossos três valores de força classificados, para ver se eles tiveram um comportamento semelhante. Essas respostas satisfizeram este estudo offline. No entanto, para validar adequadamente o modelo e o sistema de controle, é necessária uma máquina CPM/CAM e mais atributos para estabelecer um aplicativo online.

O controlador (compensador) proposto para o sistema de controle em malha fechada deste trabalho teve sua estabilidade validada pelo critério de Nyquist assim como a localização geométrica das raízes. Em ambos os métodos, foi possível observar, através das figuras 33 e 34, que os polos estão no semiplano s da direita, conseqüentemente o sistema de controle é estável.

8 CONCLUSÕES FINAIS

Dado o contexto, este estudo apresentou baixo desvio padrão (em média inferior a 2,5%) em relação aos processos de extração de características (valores de energia) entre as classes (níveis de força) de acordo com a Tabela 2, provando que é possível encontrar um padrão de energia para cada valor da força. Dessa maneira, o classificador de sinais de EMG baseado nas redes neurais artificiais propostas mostrou alta precisão no reconhecimento de padrões, classificando 81% das amostras (Figura 31) usando apenas dois atributos de caracterização: o comprimento da forma de onda e a energia do sinal.

As medidas de tempo de execução mostraram que nosso algoritmo é capaz de processar e classificar uma única contração em 62 milissegundos (baixo esforço computacional) com uma rede neural artificial superficial (10 neurônios na camada oculta). Por meio, através deste trabalho e dos resultados mostrados, é possível usar a análise eletromiográfica de músculos isolados para criar um *feedback* e usá-lo nas estratégias de controle de máquinas de CPM/CAM do joelho.

A avaliação da estabilidade do controlador proposto também permitiu provar que é possível projetar um controle em malha fechada estável e funcional, dentro das condições de contorno do problema real.

9 TRABALHOS FUTUROS

O método de controle de *feedback* baseado na análise eletromiográfica mostrou resultados promissores para aplicações futuras (alta precisão com um baixo tempo de processamento) que requerem abordagens em tempo real e podem ser estendidos a outras áreas relacionadas que envolvem biomecânica, por exemplo, braços e pernas biônicos.

Nesse contexto, por meio deste estudo, surgem novas maneiras de se realizar exercícios físicos em academias, pois é possível avaliar e controlar os movimentos do usuário através da eletromiografia muscular isolada. Por meio da utilização de inteligência artificial é possível criar máquinas inteligentes capazes de identificar e prever pontos de falha ou fadiga do usuário durante o exercício, sendo possível realizar exercícios de musculação sem a supervisão humana e de maneira muito mais eficiente.

Por outro lado, este trabalho promove a criação de dispositivos cibernéticos inteligentes que associados a eletromiografia e um sistema de controle em malha fechada, possibilitam a pacientes em recuperação realizar terapias de modo muito mais fácil, através do esforço combinado entre usuário e máquina.

Referências

- ALPAYDIN, E. *Introduction to machine learning*. [S.l.]: MIT press, 2009. 22, 30, 38, 39
- AMRANI, M. Z.-E.-A. et al. Artificial neural networks based myoelectric control system for automatic assistance in hand rehabilitation. In: IEEE. *2017 26th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*. [S.l.], 2017. p. 968–973. 27, 28, 30, 47, 56, 57, 58, 60, 69
- ARTROMOT. *Operation Instructions Manual*. [S.l.], 2013. Disponível em: <<https://www.manualslib.com/manual/1513228/Djo-Global-Artromot-Active-K.html>>. Acesso em: 27.09.2019. 30, 33, 34
- ÅSTRÖM, K. J.; WITTENMARK, B. *Adaptive control*. [S.l.]: Courier Corporation, 2013. 45
- CALLEGARO, A. M. et al. Aplicação da movimentação passiva contínua (cpm) na reabilitação do cotovelo: uma revisão da literatura. *O Mundo da Saúde*, v. 2, p. 268–275, 2010. 21, 22, 32
- CUI, Z. et al. Estimation of upper limb muscle stiffness based on artificial neural network. In: IEEE. *2017 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. [S.l.], 2017. p. 2069–2074. 29, 41, 69
- FRIEMERT, B. et al. Bewegungsschienen in der nachbehandlung der vkb-plastik—„controlled active motion “versus „continuous passive motion “/motion machines in treatment of acl reconstructed patients:“controlled active motion” versus “continuous passive motion”. In: *Panta Rhei—Umdenken—Umdenken—*. [S.l.]: Springer, 2001. p. 393–393. 33
- FRIEMERT, B. et al. Benefits of active motion for joint position sense. *Knee Surgery, Sports Traumatology, Arthroscopy*, Springer, v. 14, n. 6, p. 564–570, 2006. 33
- HAYKIN, S. et al. Neural networks and learning machines. vol. 3 pearson. *Upper Saddle River, NJ, USA*, 2009. 30, 39, 40, 41
- HO, H.-J.; CHEN, T.-C. Hybrid cpm/cam physiotherapy device by use of active feedback control loop. In: IEEE. *First International Conference on Innovative Computing, Information and Control-Volume I (ICICIC'06)*. [S.l.], 2006. v. 2, p. 146–149. 22, 25, 42, 69
- HO, H.-J.; CHEN, T.-C. Hybrid cpm/cam physiotherapy by use of the slide-mode fuzzy neural network control. In: IEEE. *2008 3rd International Conference on Innovative Computing Information and Control*. [S.l.], 2008. p. 510–510. 22, 43, 69
- HO, H.-J.; CHEN, T.-C. Motorized cpm/cam physiotherapy device with sliding-mode fuzzy neural network control loop. *Computer methods and programs in biomedicine*, Elsevier, v. 96, n. 2, p. 96–107, 2009. 25, 26, 42, 44, 69

- HOGAN, N. Impedance control: An approach to manipulation: Part i—theory. *Journal of dynamic systems, measurement, and control*, American Society of Mechanical Engineers Digital Collection, v. 107, n. 1, p. 1–7, 1985. 42, 43
- KANDEL, E. R. et al. *Principles of neural science*. [S.l.]: McGraw-hill New York, 2000. v. 4. 34
- KINETEC. *User Manual Spectra Essential*. [S.l.], 2009. Disponível em: <[https://www-manualslib.com/manual/1511001/Kinetec-Spectra-Essential.html#manual](https://www.manualslib.com/manual/1511001/Kinetec-Spectra-Essential.html#manual)>. Acesso em: 27.09.2019. 30, 32, 42
- KISNER, C.; COLBY, L. A. Exercícios terapêuticos: fundamentos e técnicas. In: *Exercícios terapêuticos: fundamentos e técnicas*. [S.l.: s.n.], 2009. p. 1000–1000. 31, 32
- KONRAD, P. The abc of emg. 2005. 22, 26, 34, 35, 36, 37, 56, 59
- LEMURA, L. M.; DUVILLARD, S. P. V. *Fisiologia do exercício clínico: aplicação e princípios fisiológicos*. [S.l.]: Guanabara Koogan, 2006. 31
- LENSSSEN, T. A. et al. Effectiveness of prolonged use of continuous passive motion (cpm), as an adjunct to physiotherapy, after total knee arthroplasty. *BMC Musculoskeletal Disorders*, BioMed Central, v. 9, n. 1, p. 60, 2008. 21, 32
- LUGER, G. F. *Inteligência Artificial-: Estruturas e estratégias para a solução de problemas complexos*. [S.l.]: Bookman, 2004. 37, 38
- MEDICINE, A. C. of S. et al. Pesquisas do acsm para a fisiologia do exercício clínico: afecções musculoesqueléticas, neuromusculares, neoplásicas, imunológicas e hematológicas. In: *Pesquisas do ACSM para a fisiologia do exercício clínico: afecções musculoesqueléticas, neuromusculares, neoplásicas, imunológicas e hematológicas*. [S.l.: s.n.], 2004. 31
- MERLETTI, R. Surface electromyography: The seniam project. *European Journal of Physical and Rehabilitation Medicine*, Edizioni Minerva Medica, v. 36, n. 4, p. 167, 2000. 53
- MERLETTI, R.; HERMENS, H. Introduction to the special issue on the seniam european concerted action. *Journal of electromyography and kinesiology: official journal of the International Society of Electrophysiological Kinesiology*, v. 10, n. 5, p. 283–286, 2000. 53
- MIOTEC. *Manual do Usuário Miotec*. [S.l.], 2008. Disponível em: <<https://www-miotec.com.br/pdf/Manual_Miograph.pdf>>. Acesso em: 27.09.2019. 54
- NAZMI, N. et al. A review of classification techniques of emg signals during isotonic and isometric contractions. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 16, n. 8, p. 1304, 2016. 30, 56, 58, 59
- NISE, N. S. *CONTROL SYSTEMS ENGINEERING, (With CD)*. [S.l.]: John Wiley & Sons, 2007. 43, 45
- RIVERA, H. R. A.; ORTEGA, A. B.; BAUTISTA, R. V. Cpm ankle rehabilitation machine with emg signal analysis. In: IEEE. *2013 International Conference on Mechatronics, Electronics and Automotive Engineering*. [S.l.], 2013. p. 164–170. 21, 22, 26, 27

- SCHULZ, M. et al. Randomized, prospective, monocentric study to compare the outcome of continuous passive motion and controlled active motion after total knee arthroplasty. *Technology and Health Care*, IOS Press, v. 26, n. 3, p. 499–506, 2018. [33](#)
- SUBASI, A. Classification of emg signals using pso optimized svm for diagnosis of neuromuscular disorders. *Computers in biology and medicine*, Elsevier, v. 43, n. 5, p. 576–586, 2013. [38](#), [39](#)
- TAN, J. C. *Practical manual of physical medicine and rehabilitation*. [S.l.]: Mosby Incorporated, 2006. [31](#), [32](#)
- TEIXEIRA-SALMELA, L. F. et al. O impacto da movimentação passiva contínua no tratamento de pacientes submetidos a artroplastia total do joelho. *Acta fisiátrica*, v. 10, n. 1, p. 21–27, 2003. [21](#)
- TORGA, D. S. Método de sintonia ótimo pid em sistema cascata: aplicação em controle de densidade de um processo simulado de remoagem. 2018. [41](#), [45](#), [46](#)
- YOUSEFI, J.; HAMILTON-WRIGHT, A. Characterizing emg data using machine-learning tools. *Computers in biology and medicine*, Elsevier, v. 51, p. 1–13, 2014. [26](#), [30](#), [35](#), [37](#), [38](#), [39](#), [60](#)

APÊNDICE A –

A.1 Termo de Consentimento Livre e Esclarecido

Eu Fabian Luis Vargas, responsável pela pesquisa: “ESTRATÉGIA DE CARACTERIZAÇÃO DE SINAIS ELETROMIOGRÁFICOS BASEADA EM REDES NEURAIS ARTIFICIAIS PARA SISTEMAS DE CONTROLE DE MÁQUINA DE CPM”, estou fazendo um convite para você participar como voluntário deste estudo. Esta pesquisa pretende validar um protocolo de registro do sinal elétrico do músculo da sua coxa denominado vasto lateral.

Este estudo é importante porque, a partir da validação do registro do sinal elétrico e da confirmação da efetividade da análise deste, poderemos utilizar essa ferramenta para a futura construção de um equipamento que auxiliará pacientes no pós-operatório de cirurgia de joelho.

Sua participação consiste no seguinte: será analisada a ativação muscular através de um exame chamado eletromiografia, no músculo da sua coxa (vasto lateral) durante a realização de dois tipos de exercícios: (1) extensão de joelho com diferentes cargas: 6, 12 e 18kg e (2) teste de força máxima, no qual você será solicitado a esticar o joelho com pesos crescentes até que não consiga mais levantar. Durante esses exercícios será coletado o sinal elétrico do seu músculo através da eletromiografia. Para tanto será necessária a preparação da pele (retirada de pelos com gilete descartável, e limpeza da pele usando papel toalha com álcool) do local (região final da sua coxa próximo ao joelho) onde serão colocados os dois eletrodos auto-adesivos – também será colocado um terceiro eletrodo na região lateral do seu tornozelo. Sua participação é voluntária.

O risco de sua participação na pesquisa é mínimo, podendo envolver: pequena reação alérgica na região da depilação (coceira ou vermelhidão) e dor muscular na sua coxa aproximadamente 36 horas após a realização do exercício.

Durante todo o período da pesquisa você tem o direito de esclarecer qualquer dúvida ou pedir qualquer outro esclarecimento, bastando para isso entrar em contato, com o pesquisador responsável (Fabian Luis Vargas), pelo telefone (51-981112389) ou e-mail (vargas@pucrs.br) ou com o Comitê de Ética em Pesquisa da PUCRS no horário de atendimento 8:00 às 12:00 e das 14:00 às 17:00, pelo telefone 5133203345, no endereço Av. Ipiranga, 6681-prédio 40, sala 505, Porto Alegre – RS/ Brasil CEP 90619-900 ou pelo e-mail cep@pucrs.br.

Você tem garantido o seu direito de não aceitar participar ou de retirar sua permis-

são, a qualquer momento, sem nenhum tipo de prejuízo pela sua decisão. Nesse contexto, você tem o direito de pedir uma indenização por qualquer dano que resulte da sua participação no estudo.

Os seus dados de identificação serão mantidos em sigilo. As informações desta pesquisa serão divulgadas em eventos e/ou publicações científicas. Eu, "NOME DO VOLUNTARIO", após a leitura deste documento e ter tido a oportunidade de conversar com o pesquisador, para esclarecer todas as minhas dúvidas, acredito estar suficientemente informado, ficando claro para mim que minha participação é voluntária e que posso retirar este consentimento a qualquer momento sem penalidades ou perda de qualquer benefício.

Estou ciente também dos objetivos da pesquisa, dos procedimentos aos quais serei submetido, dos possíveis danos ou riscos deles provenientes e da garantia de confidencialidade e esclarecimentos sempre que desejar. Diante do exposto expresso minha concordância, de espontânea vontade, em participar deste estudo. Este termo foi assinado em duas vias e fiquei com uma cópia.

Assinatura do voluntário ou de seu representante legal

Nome e Assinatura do responsável pela obtenção do TCLE

Anexos

PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Estratégia de Identificação de Padrões Eletromiográficos e Controle Baseada Nesta Identificação

Pesquisador: FABIAN LUIS VARGAS

Área Temática:

Versão: 2

CAAE: 18140819.0.0000.5336

Instituição Proponente: UNIAO BRASILEIRA DE EDUCACAO E ASSISTENCIA

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 3.544.339

Apresentação do Projeto:

O projeto propõe o desenvolvimento de uma estratégia de identificação de padrões eletromiográficos e um sistema de controle baseado em abordagem. Isto é, a classificação e identificação de padrões de esforços presentes nos sinais eletromiográficos de dez voluntários, indivíduos do sexo masculino, com idade entre 18 e 30 anos, aparentemente saudáveis, que aceitem participar do estudo, após a leitura do termo de consentimento livre e esclarecido, que serão realizados por meio de uma rede neural artificial. Inicialmente será realizada a eletromiografia do músculo vasto lateral da coxa, do membro inferior dominante, com e sem esforço (carga). A estratégia proposta neste trabalho, pode ser aplicada em máquinas de terapia passiva contínua (Continuous Passive Motion-CPM) de modo a auxiliar o paciente na realização do movimento, assim o movimento (homem-máquina) executado passará a ser ativo-assistido (Continuous ActiveMotion-CPM).

Objetivo da Pesquisa:

O objetivo principal deste estudo é o desenvolvimento de uma estratégia de identificação de padrões eletromiográficos e controle baseado nesta abordagem. Através da aplicação desta estratégia em um modelo computacional equivalente ao de máquinas de CPM, é possível simular o seu funcionamento em malha fechada. Desta forma, simulando o esforço cooperado entre o equipamento e o usuário, e assim permitindo simular um movimento ativo-assistido (CAM).

Endereço: Av.Ipiranga, 6681, prédio 50, sala 703

Bairro: Partenon

CEP: 90.619-900

UF: RS

Município: PORTO ALEGRE

Telefone: (51)3320-3345

Fax: (51)3320-3345

E-mail: cep@puhrs.br

Continuação do Parecer: 3.544.339

Avaliação dos Riscos e Benefícios:

Benefícios: Este estudo é importante porque, a partir da validação do registro do sinal elétrico e da confirmação da efetividade da análise deste, poderemos utilizar essa ferramenta para a futura construção de um equipamento que auxiliará pacientes no pós-operatório de cirurgia de joelho.

Riscos: O risco de sua participação na pesquisa é mínimo, podendo envolver: pequena reação alérgica na região da depilação (coceira ou vermelhidão) e dor muscular na sua coxa aproximadamente 36 horas após a realização do exercício.

Comentários e Considerações sobre a Pesquisa:

Estima-se que após concluído este estudo piloto sobre a utilização de eletromiografia como biofeedback para a implementação de um sistema de controle em malha-fechada para máquinas de CPM, seja possível construir protótipos para teste definitivo da estratégia desenvolvida, bem como um estudo clínico.

Em um posterior estudo clínico, será possível estudar os benefícios que o movimento ativo-assistido baseado em eletromiografia poderá trazer aos pacientes que demandam de fisioterapia após terem passado por alguma cirurgia no joelho.

Considerações sobre os Termos de apresentação obrigatória:

Todos os termos foram apresentados.

Conclusões ou Pendências e Lista de Inadequações:

Não há pendências.

Considerações Finais a critério do CEP:

Diante do exposto, o CEP-PUCRS, de acordo com suas atribuições definidas na Resolução CNS n° 466 de 2012 e a Norma Operacional n° 001 de 2013 do CNS, manifesta-se pela aprovação do projeto de pesquisa "Estratégia de Identificação de Padrões Eletromiográficos e Controle Baseada Nesta Identificação" proposto por FABIAN LUIS VARGAS com número de CAAE 18140819.0.0000.5336.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1342629.pdf	24/08/2019 11:18:37		Aceito
Outros	CartaRespostaPendencia.pdf	24/08/2019	GREGORI	Aceito

Endereço: Av. Ipiranga, 6681, prédio 50, sala 703

Bairro: Partenon

CEP: 90.619-900

UF: RS

Município: PORTO ALEGRE

Telefone: (51)3320-3345

Fax: (51)3320-3345

E-mail: cep@puhrs.br

PONTIFÍCIA UNIVERSIDADE
CATÓLICA DO RIO GRANDE
DO SUL - PUC/RS



Continuação do Parecer: 3.544.339

Outros	CartaRespostaPendencia.pdf	11:13:21	STEFANELLO SPONCHIADO	Aceito
Outros	cartaRespostaPendencias.doc	24/08/2019 11:12:59	GREGORI STEFANELLO SPONCHIADO	Aceito
Projeto Detalhado / Brochura Investigador	projeto_gregori_v3.docx	06/08/2019 22:51:32	GREGORI STEFANELLO SPONCHIADO	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	assentimento_v2.docx	06/08/2019 22:47:17	GREGORI STEFANELLO SPONCHIADO	Aceito
Folha de Rosto	folharostoassinada.pdf	24/04/2019 19:34:48	FABIAN LUIS VARGAS	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

PORTO ALEGRE, 30 de Agosto de 2019

Assinado por:
Paulo Vinicius Sporleder de Souza
(Coordenador(a))

Endereço: Av.Ipiranga, 6681, prédio 50, sala 703

Bairro: Partenon

CEP: 90.619-900

UF: RS

Município: PORTO ALEGRE

Telefone: (51)3320-3345

Fax: (51)3320-3345

E-mail: cep@puhrs.br



Pontifícia Universidade Católica do Rio Grande do Sul
Pró-Reitoria de Graduação
Av. Ipiranga, 6681 - Prédio 1 - 3º. andar
Porto Alegre - RS - Brasil
Fone: (51) 3320-3500 - Fax: (51) 3339-1564
E-mail: prograd@pucrs.br
Site: www.pucrs.br