

UnB - UNIVERSIDADE DE BRASÍLIA
FGA - FACULDADE UNB GAMA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
BIOMÉDICA

Estadiamento da Doença de Parkinson com a Utilização de
Técnicas de Aprendizado de Máquinas

Jorge Luiz Ferreira da Silva Junior

ORIENTADORA: Dra. Lourdes Mattos Brasil
CO-ORIENTADORA: Dra. Vera Regina Fernandes da Silva Marães

DISSERTAÇÃO DE MESTRADO EM ENGENHARIA BIOMÉDICA

PUBLICAÇÃO: 101A / 2018
BRASÍLIA/DF: NOVEMBRO – 2018


**UNIVERSIDADE DE BRASÍLIA
FACULDADE DO GAMA
ENGENHARIA BIOMÉDICA**

**"ESTADIAMENTO DA DOENÇA DE PARKINSON COM A
UTILIZAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINAS"**

JORGE LUIZ FERREIRA DA SILVA JUNIOR

**DISSERTAÇÃO DE Mestrado submetida à Faculdade UnB Gama da
Universidade de Brasília, como parte dos requisitos necessários para
a obtenção do título de Mestre em Engenharia Biomédica.**

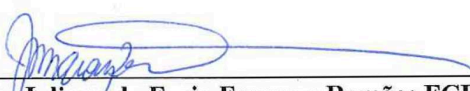
APROVADA POR:



**Profa. Dra. Vera Regina Fernandes da Silva Marães; FCE / UnB
(ORIENTADOR)**



**Prof. Dr. Ronni Geraldo Gomes de Amorim; FGA / UnB
(EXAMINADOR INTERNO)**



**Profa. Dra. Juliana de Faria Fracon e Romão; FCE / UnB
(EXAMINADOR EXTERNO)**

Brasília, 28 de novembro de 2018

BRASÍLIA/DF, 28 DE NOVEMBRO DE 2018

FICHA CATALOGRÁFICA

Jorge Luiz Ferreira da Silva Junior
Estadiamento da Doença de Parkinson com a Utilização de Técnicas de Aprendizado de Máquinas, [Distrito Federal] 2018.
101A . 93 p., 210 x 297 mm (FGA/UnB Gama, Mestre, Engenharia Biomédica, 2018).
Dissertação de Mestrado - Universidade de Brasília. Faculdade Gama. Programa de Pós-Graduação em Engenharia Biomédica.

1. Doença de Parkinson. 2. Aprendizado de Máquina
3. Estadiamento. 4. sEMG

I. FGA UnB Gama/ UnB. II. Estadiamento da Doença de Parkinson com a Utilização de Técnicas de Aprendizado de Máquinas

CDU: N° da CDU (biblioteca)

REFERÊNCIA BIBLIOGRÁFICA

Junior, J.L.F.S. (2018). Estadiamento da Doença de Parkinson com a Utilização de Técnicas de Aprendizado de Máquinas. Dissertação de Mestrado em Engenharia Biomédica, Publicação NO./2018, Programa de Pós-Graduação em Engenharia Biomédica, Faculdade Gama, Universidade de Brasília, Brasília, DF, 93 p.

CESSÃO DE DIREITOS

AUTOR: Jorge Luiz Ferreira da Silva Junior

TÍTULO: Estadiamento da Doença de Parkinson com a Utilização de Técnicas de Aprendizado de Máquinas

GRAU: Mestre

ANO: 2018

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

2018.

QI-06, Lote 560.

CEP: 72445-060, Brasília, DF – Brasil

DEDICATÓRIA

Dedico este trabalho a minha esposa, por me apoiar e acreditar em meus sonhos.

AGRADECIMENTOS

Agradeço a Dra. Lourdes Mattos Brasil, por toda atenção, paciência e apoio dados ao longo do desenvolvimento de todo o trabalho.

À Dra. Vera Regina Fernandes da Silva Marães, por todo o apoio técnico, disponibilização de equipamento e discussões sem as quais este projeto não seria possível.

Ao meu colega Roberto Aguiar Lima, por apoio e as inúmeras aulas de programação, inteligência artificial e discussões sem as quais este projeto não seria possível.

Ao minha colega Bruna da Silva Sousa, por toda colaboração no desenvolvimento do protocolo de coletas, nas coletas em si e discussões sem as quais este projeto não seria possível.

Ao meu colega Ithallo Junior Alves Guimarães, por toda colaboração no desenvolvimento do módulo de processamento de sinais e diversas discussões sobre processamento de sinais e aprendizado de máquinas sem as quais este projeto não seria possível.

À minha esposa, Thaís Leal Corrêa da Silva, por todo apoio e confiança incondicionais depositados em mim ao longo desses anos.

Laissez les bons temps rouler.

New Orleans.

RESUMO

Estadiamento da Doença de Parkinson com a Utilização de Técnicas de Aprendizado de Máquinas

Autor: Jorge Luiz Ferreira da Silva Junior

Orientadora: Profa. Dra. Lourdes Mattos Brasil

Coorientadora: Profa. Dra. Vera Regina Fernandes da Silva Marães

Programa de Pós-Graduação em Engenharia Biomédica – Mestrado

BRASÍLIA/DF 2018

O diagnóstico precoce da Doença de Parkinson (DP) é de suma importância para tratamento da doença, pois, o quanto antes for iniciado o tratamento melhores serão as chances de reversão do quadro clínico. Apesar de não haver cura, existem tratamentos que visam a combater os sintomas da doença. Medicamentos e cirurgias fazem parte do arsenal terapêutico, assim como sessões de fisioterapia, terapia ocupacional, fonoaudiologia e, em alguns casos, de psicologia. Porém, o diagnóstico da DP e seu nível de evolução (estadiamento), ainda é uma tarefa bastante complexa e imprecisa, realizada de forma clínica, por meio da história do paciente e de avaliação neurológica. Casos duvidosos são encaminhados para exames subsidiários como tomografia computadorizada, ressonância magnética e exames laboratoriais. O que pode acarretar erros de decisão por parte do especialista. A proposta deste trabalho é o desenvolvimento de um sistema utilizando técnicas de Aprendizado de Máquina (AM) e processamento de sinais para identificação, extração de características e classificação de diferentes níveis da DP por meio dos dados contidos em sinais eletromiográficos de superfície (sEMG). O sistema tem como finalidade fornecer uma segunda opinião confiável e eficiente para médicos neurologistas que venham a utilizar.

Palavras-chave: Doença de Parkinson, Aprendizado de Máquina, Estadiamento, sEMG.

ABSTRACT

Parkinson Disease Staging Through Machine Learning Techniques

Author: Jorge Luiz Ferreira da Silva Junior

Supervisor: Profa. Dra. Lourdes Mattos Brasil

Co-supervisor: Profa. Dra. Vera Regina Fernandes da Silva Marães

Post-Graduation Program in Biomedical Engineering – Master Degree

BRASÍLIA/DF 2018

Early diagnosis of Parkinson's Disease (PD) is of paramount importance for the treatment of the disease. For, the earlier treatment is started the better the chances of reversal of the clinical picture. Although there is no cure, there are treatments that aim to combat the symptoms of the disease. Medications and surgeries are part of the therapeutic arsenal, as well as physiotherapy, occupational therapy, speech therapy and, in some cases, psychology sessions. However, the diagnosis of PD and its level of evolution (staging) is still a rather complex and imprecise task, performed clinically, through the patient's history and neurological evaluation. Doubtful cases are referred to subsidiary exams such as computed tomography, MRI, and laboratory tests. This can lead to errors of decision by the expert. The proposal of this work is the development of a system using techniques of machine learning (ML) and signal processing for identification, extraction of characteristics and classification of different levels of PD through the data contained in surface electromyographic signals. The system is intended to provide a reliable and efficient second opinion for neurological physicians who may use it.

Key-words: Parkinson's Disease, Machine Learning, Staging, sEMG.

SUMÁRIO

1	INTRODUÇÃO	16
1.1	CONTEXTUALIZAÇÃO E FORMULAÇÃO DO PROBLEMA	16
1.2	OBJETIVOS	17
1.2.1	Objetivo Geral	17
1.2.2	Objetivos Específicos	17
1.3	REVISÃO DA LITERATURA	17
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	A DOENÇA DE PARKINSON	19
2.1.1	Estadiamento da Doença de Parkinson	22
2.1.2	Tratamento da Doença de Parkinson	24
2.1.3	Tremores	25
2.2	PROCESSAMENTO DE SINAIS	25
2.2.1	Filtros Digitais	25
2.2.2	Transformada Rápida de Fourier	26
2.3	APRENDIZADO DE MÁQUINA	28
2.3.1	Aprendizado Supervisionado	28
2.3.2	Aprendizado Não Supervisionado	29
2.3.3	Aprendizado Por Reforço	29
2.3.4	<i>Random Forest</i>	29
2.3.5	<i>Support Vector Machine</i>	30
2.3.6	<i>K-Nearest Neighbors</i>	31
2.4	ANÁLISE ESTATÍSTICA	32
2.4.1	Matriz de Confusão	32
2.4.2	<i>Principal Components Analysis</i>	33
3	METODOLOGIA	35
3.1	COLETA E ANÁLISE DE DADOS	35
3.1.1	Protocolo para Coleta de Sinais EMG	37
3.1.2	Coleta 1 - Tremor de Repouso	38
3.1.3	Coleta 2 - Tremor Isométrico	39
3.1.4	Coleta 3 - Tremor de Ação	39
3.1.5	Coleta 4 - Tremor de Intenção	40
3.1.6	Extração de Características	41
3.1.7	Classificação de Características	42
3.1.8	Análise de Desempenho	42

3.2	INTERFACE DE OPERAÇÃO DO USUÁRIO	43
3.3	DELIMITAÇÃO DO ESTUDO	44
3.4	RECURSOS TECNOLÓGICOS	44
3.5	RESTRICÇÕES	44
4	RESULTADOS	45
4.1	CLASSIFICAÇÃO DOS NÍVEIS DE ESTADIAMENTO DA DOENÇA DE PARKINSON	45
4.1.1	Treinamento SVM-RBF	45
4.1.2	Treinamento SVM-Poly	47
4.1.3	Treinamento RF	48
4.1.4	Treinamento KNN	50
4.1.5	Validação do Sistema Pelo Profissional da Saúde	51
4.1.6	Produção Intelectual	52
5	DISCUSSÃO E CONCLUSÃO	54
6	TRABALHOS FUTUROS	56
	REFERÊNCIAS BIBLIOGRÁFICAS	57
	ANEXOS	61
	ANEXO A – TERMO DE CONSENTIMENTO LIVRE E ESCLA- RECIDO	62
	ANEXO B – CERTIFICADO DE APRESENTAÇÃO COBEC-SEB 2017	63
	ANEXO C – CERTIFICADO DE PUBLICAÇÃO DE ARTIGO COBEC- SEB 2017	64
	ANEXO D – CERTIFICADO DE PUBLICAÇÃO DE ARTIGO COBEC- SEB 2017	65
	ANEXO E – MENÇÃO HONROSA DE MELHOR TRABALHO DO CONGRESSO COBEC-SEB 2017	66
	APÊNDICES	67
	APÊNDICE A – INTERFACE DE OPERAÇÃO DO USUÁRIO . . .	68

APÊNDICE B – EXEMPLO DE CLASSIFICAÇÃO DE UMA AMOSTRA NÍVEL 3 NA ESCALA H-Y	69
APÊNDICE C – ARTIGO COMPLETO 1 COBEC-SEB 2017 . . .	75
APÊNDICE D – ARTIGO COMPLETO 2 COBEC-SEB 2017 . . .	79
APÊNDICE E – ARTIGO COMPLETO 3 COBEC-SEB 2017 . . .	82
APÊNDICE F – ARTIGO COMPLETO 4 CBEB 2018	86

LISTA DE TABELAS

Tabela 1 – Estadiamento da DP pela escala Hoehn & Yahr (Adaptado de (GAGO, 2014).	23
Tabela 2 – Filtros e suas funções (Adaptado de (LACANETTE, 1991).	26
Tabela 3 – Perfis dos voluntários Parkinsonianos.	36
Tabela 4 – Perfis dos voluntários do grupo controle.	37
Tabela 5 – Intervalo de parâmetros utilizados.	42
Tabela 6 – Métricas SVM-RBF.	46
Tabela 7 – Métricas SVM-Poly.	47
Tabela 8 – Métricas RF.	48
Tabela 9 – Métricas KNN.	50
Tabela 10 – Artigos produzidos.	53

LISTA DE ILUSTRAÇÕES

Figura 1 – Morte de neurônios da substância negra na doença de Parkinson (ATRAIN, 2008).	19
Figura 2 – Neurotransmissor dopamina e suas desordens na DP (ATRAIN, 2008).	20
Figura 3 – Exemplo de árvore de decisão (RASCHKA, 2015).	30
Figura 4 – Atribuição de classe por maioria de votos. Adaptado de (RASCHKA, 2015)	31
Figura 5 – Curva ROC	33
Figura 6 – Fluxograma de desenvolvimento da pesquisa.	35
Figura 7 – Eletromiógrafo <i>Miotool</i> utilizado para coleta dos sinais sEMG (MIOTECH, 2017).	37
Figura 8 – Posicionamento de eletrodos para captação de tremores de repouso (MIOTECH, 2017).	39
Figura 9 – Posicionamento de eletrodos para captação de tremores isométrico (MIOTECH, 2017).	39
Figura 10 – Posicionamento de eletrodos para captação de tremores de ação (MIOTECH, 2017).	40
Figura 11 – Posicionamento de eletrodos para captação de tremores de intenção (MIOTECH, 2017).	41
Figura 12 – Etapas da extração de características.	43
Figura 13 – Matriz de Confusão SVM-RBF.	45
Figura 14 – Curva ROC SVM-RBF.	46
Figura 15 – Matriz de Confusão SVM-Poly.	47
Figura 16 – Curva ROC SVM-Poly.	48
Figura 17 – Matriz de Confusão SVM-RF.	49
Figura 18 – Curva ROC RF.	49
Figura 19 – Matriz de Confusão KNN.	50
Figura 20 – Curva ROC KNN.	51
Figura 21 – Resumo do relatório gerado pelo sistema.	52

LISTA DE ABREVIATURAS E SIGLAS

ACM	<i>Association for Computing Machinery</i>
AM	Aprendizado de Máquinas
AUC	<i>Area Under the Curve</i>
AVC	Acidente Vascular Cerebral
BIREME	Biblioteca Virtual em Saúde
BM	<i>Boltzmann Machine</i>
CAAE	Certificado de Apresentação para Apreciação Ética
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CEP	Comitê de Ética em Pesquisa
DFT	<i>Discrete Fourier Transform</i>
DP	Doença de Parkinson
EC	Extração de Características
ECP	Estimulação cerebral Profunda
EDF	<i>European Data Format</i>
FFT	<i>Fast Fourier Transform</i>
FS	Faculdade de Saúde
H-Y	<i>Hoehn & Yahr</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
KNN	<i>K-Nearest Neighbors</i>
MEB	Modelos Baseados em Energia
PCA	<i>Principal Component Analysis</i>
PEDRo	<i>Physiotherapy Evidence Database</i>
PubMed	<i>Publications in Medicine</i>

RMS	<i>Root Mean Square</i>
RNA	Rede Neural Artificial
ROC	<i>Receiver Operating Characteristic</i>
sEMG	<i>Surface Electromyography</i>
SENIAM	<i>Surface Electromyography for the Non-Invasive Assessment of Muscles</i>
SVM	<i>Support Vector Machine</i>
TCLE	Termo de Consentimento Livre e Esclarecido
UnB	Universidade de Brasília
UPDRS	<i>Unified Parkinson's Disease Rating Scale</i>

LISTA DE SÍMBOLOS

Símbolos Latinos

x	Vetor de características
p	Potência
k	Matriz de similaridade
exp	Função exponencial
T	Função Transposta

Símbolos Gregos

θ	Limiar
γ	Parâmetro de ajuste do kernel RBF

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E FORMULAÇÃO DO PROBLEMA

A Doença de Parkinson (DP), descrita por James Parkinson em 1817, é hoje uma das doenças neurológicas mais comuns e intrigantes. Tem distribuição universal e atinge todos os grupos étnicos e classes sócio-econômicas (WATTS; KOOLE, 2004). A idade é um importante fator de risco, porém não o único. A doença é comumente relatada em população idosa onde a cada 1000 pessoas com 65 anos uma é afetada e a cada 100 pessoas com mais de 75 anos uma é afetada. Ainda, é notório que a doença acomete mais os indivíduos do sexo masculino, a proporção é 2:1 (MELLO; BOTELHO, 2010). Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE) no Brasil são aproximadamente 36 mil novos casos por ano.

O tratamento para a DP é medicamentoso associado à prática de exercícios físicos. O tratamento tem como objetivo minimizar a progressão da doença, melhorar a funcionalidade do acometido, prevenir as complicações secundárias e aumentar a qualidade de vida (ABBRUZZESE et al., 2016). Porém, a fisioterapia convencional pode ser interpretada pelo paciente como desmotivante (POMPEU et al., 2014). Quando os exercícios físicos são realizados no início dos sintomas motores, eles conseguem retardar a progressão da doença por estimular a neuroplasticidade (GOODWIN et al., 2008; KING; HORAK, 2009).

Este trabalho propõe a criação de um sistema para classificação do estadiamento da DP com o apoio de algoritmos utilizando técnicas de Aprendizado de Máquina (AM).

O AM tem recebido grande atenção nos últimos anos devido o aumento da capacidade computacional tornando mais barato e robusto o processamento de algoritmos em uma grande massa de dados (GUESTRIN; FOX, 2016; MALONE; THRUN, 2016) (GUESTRIN; FOX, 2016). Como um subcampo da inteligência artificial, o AM compõem um conjunto de algoritmos de autoaprendizagem capaz de adquirir conhecimento a partir de um banco de dados para realizar tomadas de decisões e fazer previsões (RASCHKA, 2015). Métodos de AM têm sido amplamente utilizados para o reconhecimento e a classificação de padrões (RASCHKA, 2015; BISHOP, 2006; HENRIK; RICHARDS; FETTEROLF, 2016; GOLLAPUDI, 2016), mostrando-se uma forte ferramenta para o trabalho proposto.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Este trabalho tem por objetivo principal o desenvolvimento de um sistema capaz de auxiliar o profissional da saúde na realização do estadiamento da DP de acordo com a escala *Hoehn & Yahr* (H-Y).

1.2.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Coletar dados de eletromiografia de superfície;
- Realizar o pré processamento dos sinais sEMG por meio de filtros digitais;
- Realizar a extração de características dos sinais sEMG pré processados;
- Classificar as características extraídas;
- Permitir a generalização dos sinais sEMG utilizadas como entrada do sistema;
- Desenvolver um sistema de baixo custo;
- Validar o sistema proposto.

1.3 REVISÃO DA LITERATURA

A pesquisa da base bibliográfica utilizada neste trabalho considerou a busca por livros, teses, monografias e artigos nas seguintes fontes especializadas: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), *Publications in Medicine* (PubMed), *Association for Computing Machinery* (ACM), *Institute of Electrical and Electronics Engineers* (IEEE), *Physiotherapy Evidence Database* (PEDro) e Biblioteca Virtual em Saúde (BIREME). Para a realização da pesquisa foram utilizadas as seguintes palavras-chave na língua portuguesa: Doença de Parkinson, Estadiamento, Escalas de avaliação, Análise de marcha, Distúrbios de movimento, Eletromiografia e suas respectivas siglas.

Foram utilizadas também palavras-chave na língua inglesa, como: Parkinson's disease, Gait analysis, Movement disorders, Rating scale, Surface Electromyography (sEMG) activity, Disease progression e Machine learning. Assim como suas respectivas siglas.

Dentre os trabalhos encontrados e analisados seguem as descrições das obras que mais se correlacionaram com o objetivo desta dissertação.

No trabalho de JOSHI; KHAJURIA; JOSHI (2017) foi apresentada uma metodologia não invasiva para classificação da DP. É utilizada a análise de *Wavelet* combinada com

Support Vector Machine (SVM) à variáveis espaço-temporais da marcha. Os voluntários que participaram desta pesquisa se encontravam entre os níveis 1,5 a 2,5 e 3 a 4 na escala *Hoehn & Yahr*. Contudo, a classificação realizada neste trabalho foi apenas se o voluntário possui ou não a DP.

No artigo apresentado por RUONALA et al. (2014) foi realizado um estudo que propôs a identificação de voluntários com a DP e de voluntários com tremor de essencial através de dados eletromiográficos do bíceps braquial durante a tensão isométrica. Utilizou-se a técnica de redução de dimensão *Principal Component Analysis* (PCA) em histogramas de pequenos segmentos dos sinais eletromiográficos. Foram determinados também três parâmetros para mensuração cinemática, amplitude RMS, entropia de amostragem e frequência de pico.

Na obra de ROBICHAUD et al. (2009) foi mostrado um estudo que avaliou mudanças no padrão eletromiográfico durante movimentos rápidos em indivíduos diagnosticados com DP. Foi proposto também a distinção de indivíduos com DP de indivíduos saudáveis e a determinação de diferenças no padrão eletromiográfico que refletiam a gravidade da doença na DP.

No trabalho de MEIGAL et al. (2009) foram analisados os sinais eletromiográficos do músculo bíceps braquial quando realizado movimentos com diferentes níveis de carga e, então identificar qual nível de carga do bíceps braquial que provavelmente diferenciaria o grupo com DP do grupo controle. Este estudo indicou também a dimensão de correlação e entropia de amostra que foram significativamente diferentes entre os pacientes com DP e controles saudáveis. Esses novos parâmetros não lineares, ao contrário dos parâmetros espectrais tradicionais ou de amplitude, correlacionaram-se com a Escala Unificada de Avaliação de Doenças de Parkinson (UPDRS) e os escores de toque de dedos.

Nas bases de dados pesquisadas não foram encontrados nenhum registro de técnicas de AM sendo utilizadas para classificação da DP em níveis como a escala *Hoehn e Yahr*.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 A DOENÇA DE PARKINSON

Com o envelhecimento populacional e o conseqüente aumento do número de idosos, a incidência e prevalência de doenças crônicas, degenerativas e múltiplas vem aumentando ao longo dos anos, sendo acentuado pela redução da mortalidade infantil, aumento da expectativa de vida e pela diminuição das taxas de fecundidade (TANNURE et al., 2010). Estudos nas áreas de Geriatria e Gerontologia afirmam que após a inserção na faixa etária característica como idoso (60 a 70 anos), os indivíduos devem apresentar pelo menos uma doença crônica, de característica não transmissível, sendo que as doenças crônicas de modo geral afetam a funcionalidade e a qualidade de vida de seus portadores (ARAÚJO; BACHION, 2004). Dentro desse contexto surge a DP, uma doença neurodegenerativa do sistema nervoso central, causada pela morte dos neurônios da substância negra presente no mesencéfalo e do lócus cerúleos, responsáveis pela produção de dopamina (WERNECK, 2010). A Figura 1 exemplifica a perda da substância negra no mesencéfalo. Estima-se que em 2020, mais de 40 milhões de pessoas no mundo terão distúrbios motores secundários à DP, enquanto no Brasil a estimativa é de que 3% da população de idosos tenha Parkinson e que ocorrerá o surgimento de 36 mil novos casos por ano da doença (IBGE, 2011).




Figura 1 – Morte de neurônios da substância negra na doença de Parkinson (ATRAN, 2008).

A dopamina trata-se de um neurotransmissor, ou seja, é uma substância química que transmite informações entre neurônios em toda a área cerebral. Cada neurotransmissor apresenta a quantidade de moléculas ideal para a captação dos seus receptores, sendo estes específicos para cada substância devido as diferentes funções cerebrais, em especial, a dopamina por ser um neurotransmissor da via nigroestriatal e cortical é responsável por demandas associadas ao sistema motor, controle motor e pelas respostas emocionais, es-

tando ainda ligada aos comportamentos repetitivos. Na doença de Parkinson, o número de moléculas apresenta-se cada vez mais reduzido, apresentando dificuldade na manutenção do funcionamento das áreas cerebrais que apresentam maiores quantidades de receptores dopaminérgicos, como a substancia negra (SHIH et al., 2006). A Figura 2 exemplifica a redução de moléculas de dopamina.




Figura 2 – Neurotransmissor dopamina e suas desordens na DP (ATRRAIN, 2008).

Mesmo a DP apresentando uma etiologia idiopática, diversos estudos apresentam correlações com aspectos genéticos, ambientais, além do processo de envelhecimento sendo este biológico com ligação direta a perda de neurotransmissores e perda neuronal de forma progressiva (SOUZA et al., 2011). Dentre os principais fatores externos que podem desencadear a DP podemos citar drogas (neurolépticos, antieméticos, antidepressivos inibidores de recaptção de serotonina e duais), intoxicação exógenas (manganês, monóxido de carbono, herbicidas, metanol), infecções (encefalites virais, neurocisticercose e síndrome da imunodeficiência adquirida), doença vascular cerebral e traumatismo cranioencefálico (BARBOSA; SALLEM, 2005).

As relações ambientais estão associadas a diversas exposições a toxinas de origem tóxica que podem levar ao estresse oxidativo e a perda mitocondrial, de forma que essas etiologias estão todas associadas as características motoras e não motoras da DP, sendo de extrema importância para o presente estudo as causas motoras, forma de diagnóstico

e, conseqüentemente, o estadiamento da Doença de Parkinson.

As alterações motoras da DP estão classificadas entre alterações de movimento, cognitivas influenciando os aspectos motores e, por fim, posturais, que são percebidas quando o paciente apresenta uma considerável perda neuronal dopaminérgica e redução do seu conteúdo na substância negra e *locus cerúleos*, em torno de 80% inferior aos valores dentro da normalidade (LANA et al., 2007).

Sendo que essas alterações motoras clínicas mais características da doença de Parkinson, são: tremor em repouso, rigidez, alterações posturais, bradicinesia, perda de reflexos posturais e, por fim, o congelamento. Essas alterações afetam tanto os membros superiores quanto os membros inferiores. Sendo que o tremor de repouso é uma das características mais evidentes e conhecidas, sendo caracterizada pela frequência de 4 a 5 Hz, podem aparecer em membros superiores, lábios, queixo e línguas, de maneira geral com a execução do movimento o tremor tende a atenuar-se, tendo como agravante a execução da marcha ou estresse (com a sugestão de outro movimento que exija mais atuação do sistema motor) (MOREIRA et al., 2007).

A rigidez apresenta-se principalmente a nível muscular podendo ou não estar associada a alterações articulares, apresentando uma resistência ao movimento passivo, sendo expressivo pelo Sinal da Roda Denteada, sendo estes um dos testes para a verificação dos seis sinais da DP. A rigidez também está incluída nas alterações posturais da doença de Parkinson, alterando o padrão de musculaturas responsáveis pela estabilização da coluna, de forma que alguns sinais como a cifose e a flexão de quadris e joelhos são muito frequentes nos pacientes com a patologia em estudo (SOUZA et al., 2011).

A bradicinesia e a hipocinesia ocorrem geralmente após a apresentação do tremor, com característica assimétrica na maioria dos casos, por serem características de diminuição da amplitude de movimento, lentidão, conseqüentemente há uma perda da expressão facial espontânea, com tendência a imobilidade do paciente. Além disso, a diminuição da destreza e tato fino característicos da micrografia podem afetar movimentos finos dos dedos. E, por fim, o congelamento caracterizado pelo bloqueio motor durante movimentos ativos, são mais frequentes em ações que envolvem os membros inferiores como a marcha (*freezing*), e em movimentos que envolvam punhos e dedos (BLASIUS; MERRITT, 2002).

Essas características são importantes para a formação de diagnóstico da Doença de Parkinson, sendo que os critérios clínicos para o diagnóstico estão baseados em clinicamente provável e clinicamente definida. Quando o paciente se apresenta na fase de clinicamente provável considera-se pelo menos dois sinais ou sintomas característicos. Enquanto que na fase de clinicamente definida são observadas o conjunto de pelo menos três dos sinais cardinais a doença de Parkinson, sendo esses: tremor de repouso, rigidez, bradicinesia e diminuição de reflexos, ou seja, todos com bases motoras (MOREIRA et

al., 2007).

Tendo em vista que algumas patologias apresentam características semelhantes a doença de Parkinson, tais como: parkinsonismo, síndrome de demência *Lytico- Boding*, atrofia de sistemas, síndrome *Parkinson – Plus*, dentre outras. O ideal para algumas pacientes são a realização de ressonância magnética, eletroneuromiografia, tomografia computadorizada que permitam verificar a densidade de dopamina nos neurônios, principalmente para o tratamento seja para fins protetores quanto para fins sintomáticos (NUTT, 2005).

Sendo que após a identificação da PD, o paciente apresenta uma estratificação de estágio na doença, sendo esta baseada nos comprometimentos estruturais, ou por escalas de estadiamento da doença como a escala *Hoer & Yahr* (H-Y) e a escala Escala Unificada de Avaliação na Doença de Parkinson (UPDRS) (NUTT, 2005).

2.1.1 Estadiamento da Doença de Parkinson

A respeito da estratificação por acometimento estrutural, os estágios apresentam-se divididos em: estágio 1, com o comprometimento do núcleo motor dorsal dos nervos glossofaríngeo e vago, com acometimento das fibras que inervam o putâmem dorso-lateral; estágio 2, por afetar os núcleos da rafe, núcleo reticular gigantocelular e lócus cerúcleos; estágio 3, com comprometimento da parte compacta da substância negra do mesencéfalo. Além disso, os três últimos estágios apresentam comprometimentos mais severos, sendo os estágios 4 e 5 relacionados a alterações das regiões prosencefálicas, mesocórtex temporal e do neocórtex, e por fim o estágio 6 é com neocórtex. E, por fim, áreas motoras primárias (GALHARDO; AMARAL; VIEIRA, 2009).

Enquanto a escala H-Y, criada em 1967, apresenta um estadiamento mais generalista para ser executado de forma prática, a UPDRS trata de uma escala para a DP que analisa fatores como atividade mental, comportamento, humor, atividades da vida diária (e.g. escrita, fala, etc), dentre outros diversos fatores para classificar a DP (WE MOVE, 2006).

Possuindo 5 estágios de classificação, a escala H-Y avalia alguns aspectos como tremor, rigidez, lateralidade, instabilidade postural e bradicinesia. Dessa forma, o médico ou profissional da saúde observa o paciente nas posturas ortostáticas, sedestação, durante a marcha e sua resposta ao teste do empurrão (HOEHN; YAHR, 1967; SCHENKMAN et al., 2001). A Tabela 1 mostra o estadiamento da DP de acordo com essa escala.

De forma adaptada para a língua portuguesa, o estágio 1 (é caracterizado pela doença unilateral, o estágio 1,5 pelo envolvimento unilateral e axial), o estágio 2 (doença bilateral sem comprometer o equilíbrio), o estágio 2,5 (doença bilateral leve, com recuperação no teste do empurrão), estágio 3 (doença bilateral de leve a moderada, alguma instabilidade postural, fisicamente independente), estágio 4 (Incapacidade grave, ainda

Tabela 1 – Estadiamento da DP pela escala Hoehn & Yahr (Adaptado de (GAGO, 2014)).

Estádio	Características clínicas
1	Doença unilateral
1,5	Doença unilateral e axial
2	Doença bilateral sem instabilidade postural
2,5	Doença bilateral; instabilidade postural ligeira, com recuperação no teste de retropulsão
3	Doença bilateral; instabilidade postural ligeira; independência física
4	Dificuldade significativa na marcha e na estabilidade postural, porém ainda capaz de realizar caminhadas sem ajuda
5	Incapaz de realizar caminhadas sem ajuda, preso a cadeira de rodas ou cama

capaz de ficar ereto sem ajuda). E, por fim, o 5 (preso à cadeira de rodas ou leito, a não ser que receba ajuda). Dessa forma, o médico ou profissional da saúde observa o paciente nas posturas ortostáticas, sedestação, durante a marcha e sua resposta ao teste do empurrão (HOEHN; YAHR, 1967; SCHENKMAN et al., 2001).

Alguns estudos como a tese de mestrado de LAHR (2015), apresenta uma avaliação da função motora manual de pacientes com Parkinson, fazendo uso da escala de *Fugl-Meyer*. Sendo esta, uma escala direcionada para função motora manual não sendo especializada para a doença de Parkinson. No entanto, esta escala avalia a motricidade reflexa, movimentos com e sem sinergias, atividades reflexas, controle de punho e mão, coordenação e velocidade, permitindo uma avaliação do comprometimento ou alteração dos membros superiores. É observado também, que os pacientes com Parkinson apresentaram diminuição na função de membros superiores com melhora após a intervenção fisioterapêutica. Demonstrando-se assim, que a DP afeta a mobilidade e função de membros superiores (BEER et al., 2004).

Além desse, estudos como o de BRAGA (2013) apresenta a relação do ritmo com o desempenho de membros superiores. O estudo demonstra que pacientes portadores da doença de Parkinson apresentam alterações significativas de contrologia e coordenação de membros inferiores. Contudo, não foi mencionado se há correlação entre o estadiamento e o comprometimento estrutural de membros superiores.

Após o estadiamento, seja ele estrutural ou baseado em movimentos, o médico determina o tratamento farmacológico e encaminha independentemente do estágio os pacientes para o tratamento fisioterapêutico, baseado nas alterações dos pacientes.

2.1.2 Tratamento da Doença de Parkinson

O tratamento farmacológico, apresenta como principal medicamento sintomático utilizado é a *levodopa*, que possui efeitos comportamentais diversos como: sonolência, delírios, reversão do ciclo sono-vigília, confusão mental, desativações comportamentais, dor, hipotensão ortostática, flutuações motoras entre outros. Além disso, quanto maior as doses do medicamento maior a intensidade das reações adversas. Além da *levodopa*, outros medicamentos podem causar reações adversas que podem alterar o movimento, a funcionalidade do paciente e a qualidade de vida, tais como os agonistas dopaminérgicos que podem causar edema de membros inferiores, fibrose retroperitoneal e eritromelalgia (POMPEU et al., 2014).

Enquanto o tratamento fisioterapêutico, apresenta-se baseado na execução de movimentos e modificação das alterações motoras e posturais, fazendo uso de cinesiologia e/ou realidade virtual, fazendo uso da gamificação. A fisioterapia permite o retardo da progressão da doença por estimular a neuroplasticidade, aumentando assim a qualidade de vida, enquanto a realidade virtual permite um melhor tratamento para incoordenação de membros superiores e inferiores, o uso do medicamento farmacológico afeta diretamente a execução dos movimentos. Porém, com a realização da fisioterapia esses efeitos são diminuídos, de forma que mesmo com o uso dos medicamentos farmacológicos, a realização da fisioterapia nos pacientes apresentam o fenômeno *on-off* e as discinesias (movimento involuntários anormais) (POMPEU et al., 2014; SILVA et al., 2013).

Em relação ao tratamento fisioterapêutico e os impactos das doenças, a maioria dos estudos estão relacionados com movimentos de membros inferiores e os aspectos da marcha. Contudo, os membros superiores também apresentam aspectos a serem avaliados e tratados, principalmente pela ocorrência do tremor aparecer na maioria dos casos em membros superiores (POMPEU et al., 2014; SILVA et al., 2013).

Estudos apontam também a alteração na fala do paciente acometidos com a DP. Essa alteração dá-se principalmente devido a rigidez muscular, acinesia e bradicinesia causando prejuízo da função gânglio basal (SILVEIRA; BRASOLOTTO, 2005).

Dentre as terapias mais avançadas, podemos citar:

- Estimulação cerebral Profunda ECP
 - Realizada através da introdução de um eletrodo no cérebro, o qual fornece uma corrente elétrica de forma contínua capaz de amenizar os sintomas da DP e reduzir os efeitos colaterais da medicação (VOON et al., 2005).
- Terapia celular
 - Trata-se da inserção de células tronco em determinada área do organismo com o objetivo de substituir funcionalmente células que foram perdidas no curso de

um processo degenerativo (LINDVALL; KOKAIA; MARTINEZ-SERRANO, 2004).

2.1.3 Tremores

Tendo em vista essas alterações de membros superiores, e um dos principais sinais da doença ser o tremor (geralmente identificado em membros superiores, por estarem mais comumente em repouso), alguns estudos buscam analisar características eletromiográficas com o tremor, tais como o de (HALLIDAY et al., 2000), que verificou a frequência em *hertz* do tremor essencial e em pacientes com ativação de baixa frequência do córtex motor, e o de (WHARRAD; JEFFERSON, 2000) verificando o registro de qualquer atividade muscular realizada de forma involuntária durante o repouso. Estudos como estes demonstram a importância da Eletromiografia de superfície para verificação da atividade muscular e seus níveis de potencial de ação muscular. Entretanto, até o presente momento apresentam-se escassas evidências científicas correlacionando o tremor de repouso com escalas práticas de estadiamento da doença de Parkinson.

Vale ressaltar que a doença de Parkinson tem por característica o tremor de repouso, mas não exclui as possibilidades que os pacientes possam apresentar outros tipos de tremores. Existem bem definidos na literatura além do tremor de repouso, os de ação, isométrico e o de intenção (HALLIDAY et al., 2000).

O tremor de ação ocorre durante uma ação que exija a contração voluntária dos músculos, de forma que o tremor isométrico não deixa de ser baseado em uma ação, porém exige a sustentação de um objeto ou movimento fixo. Por fim, o tremor de intenção acontece quando o paciente começa a executar ou tem um objetivo que ao ser solicitado gera um estresse promovendo o tremor (HALLIDAY et al., 2000).

2.2 PROCESSAMENTO DE SINAIS

2.2.1 Filtros Digitais

Filtros de um modo geral são indispensáveis na maioria dos circuitos eletrônicos, ou mesmo no tratamento digital de sinais. Um filtro pode ser analógico, composto por um conjunto de elementos elétricos, ou digital, implementado por uma linguagem de programação a fim de reproduzir os efeitos de um filtro analógico (LACANETTE, 1991).

Estes filtros tem como principal objetivo eliminar ruídos provenientes de equipamentos eletrônicos presentes no ambiente e até mesmo da própria rede elétrica. Uma vez que, tais interferências dificultam posteriormente a extração de informações de sinais coletados. Um grande exemplo disso é a captação de sinais de sEMG (realizada neste trabalho) que é altamente sensível a interferência da rede elétrica e de equipamentos eletrônicos como celulares e *notebooks*.

Dentre os diversos tipo de filtros existentes, os principais tipo são passa-baixas, passa-altas, passa-bandas, passa-tudo e *notch* (LACANETTE, 1991). Contudo, neste trabalho são utilizados apenas os filtros passa-baixas e passa-bandas. Resumidamente, na Tabela 2 é observado a função de cada tipo de filtro.

Tabela 2 – Filtros e suas funções (Adaptado de (LACANETTE, 1991)).

Filtro	Função
Passa-baixas	Deixa passar sinais de baixa frequência e atenua frequências acima do limiar de corte
Passa-altas	Deixa passar sinais de alta frequência e atenua frequências abaixo do limiar de corte
Passa-bandas	Separa o sinal em uma frequência específica ou em uma faixa de frequências
Passa-tudo	Altera a fase do sinal sem alterar a amplitude
<i>Notch</i>	Remove frequências indesejadas de um sinal ou uma faixa de frequências

2.2.2 Transformada Rápida de *Fourier*

A Transformada de *Fourier* é uma ferramenta matemática que possibilita a transformação entre variáveis do domínio do tempo e frequências de sinais. Esta seção tem como objetivo principal apresentar técnicas computacionais para a determinação da transformada de *Fourier* em sua forma discreta, chamada *Discrete Fourier Transform* (DFT), e a sua forma computacional calculada com algoritmos rápidos, conhecidos como *Fast Fourier Transform* (FFT).

Para melhor entendermos a DFT, partimos da forma geral da série de *Fourier* Equação 1. A série de *Fourier* é uma série trigonométrica usada para representar funções infinitas e periódicas através de funções de senos e cossenos (OPPENHEIN; SCHAFER, 1974).

$$f(x) = \frac{a_0}{2} + \sum_{n=1}^{\infty} a_n \cos \frac{n\pi x}{L} + \sum_{n=1}^{\infty} b_n \sen \frac{n\pi x}{L}. \quad (1)$$

Utilizando a fórmula de *Euler*, $e^{ix} = \cos(x) + i\sen(x)$, podemos reescrever a série de *Fourier* em sua forma compacta exponencial

$$f(x) = \sum_{n=-\infty}^{\infty} c_n e^{\frac{in\pi x}{L}}, \quad (2)$$

em que

$$c_n = \frac{1}{2L} \int_{-L}^L f(x) e^{\frac{-in\pi x}{L}} dx, \text{ para } n = 0, \pm 1, \pm 2, \dots,$$

pois,

$$a_n = \frac{1}{L} \int_{-L}^L f(x) \cos\left(\frac{n\pi x}{L}\right) dx, \text{ para } n = 0, 1, 2, \dots,$$

$$b_n = \frac{1}{L} \int_{-L}^L f(x) \operatorname{sen}\left(\frac{n\pi x}{L}\right) dx, \text{ para } n = 1, 2, \dots$$

A DFT de um vetor $Y \in \mathbb{C}^n$ é definida por

$$X = F_N Y,$$

em que

$$F_N = \frac{1}{N} \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ 1 & e^{-i2\pi \frac{1}{N}} & e^{-i2\pi \frac{2}{N}} & \dots & e^{-i2\pi \frac{N-1}{N}} \\ 1 & e^{-i2\pi \frac{2}{N}} & e^{-i2\pi \frac{4}{N}} & \dots & e^{-i2\pi \frac{2(N-1)}{N}} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & e^{-i2\pi \frac{N-1}{N}} & e^{-i2\pi \frac{2(N-1)}{N}} & \dots & e^{-i2\pi \frac{(N-1)(N-1)}{N}} \end{bmatrix}. \quad (3)$$

Seja $f : \mathbb{R} \rightarrow \mathbb{R}$ uma função tal que $f(x) = 0$, para $|x| > L$. Então

$$\hat{f}\left(\frac{n\pi}{L}\right) \approx \frac{1}{\sqrt{2\pi}} \int_{-L}^L f(x) e^{-i\pi \frac{nx}{L}} dx, \text{ para } n = 0, \pm 1, \dots, \frac{N}{2}.$$

Dessa forma, podemos aproximar a integral por uma soma de Riemann dividindo o intervalo $[0, 2L]$ em N subintervalos de comprimento $2L/N$, ou seja,

$$\hat{f}\left(\frac{n\pi}{L}\right) \approx \frac{2L}{N\sqrt{2\pi}} \left(\sum_{k=0}^{N/2-1} f\left(\frac{2kL}{N}\right) e^{-i2\pi \frac{kn}{N}} + \sum_{k=N/2}^{N-1} f\left(\frac{2kL}{N} - 2L\right) e^{-i2\pi \frac{kn}{N}} \right),$$

para $n = 0, \dots, \frac{N}{2} - 1$.

$$\hat{f}\left(\frac{(-N+n)\pi}{L}\right) \approx \frac{2L}{N\sqrt{2\pi}} \left(\sum_{k=0}^{N/2-1} f\left(\frac{2kL}{N}\right) e^{-i2\pi \frac{kn}{N}} + \sum_{k=N/2}^{N-1} f\left(\frac{2kL}{N} - 2L\right) e^{-i2\pi \frac{kn}{N}} \right),$$

para $n = \frac{N}{2}, \dots, N - 1$.

Dessa forma, definindo

$$X = \left[f(0) f\left(\frac{2L}{N}\right) \dots f\left(L - \frac{2L}{N}\right) f(-L) f\left(-L + \frac{2L}{N}\right) \dots f\left(-\frac{2L}{N}\right) \right]^t,$$

portanto

$$Y = F_N X \approx \frac{\sqrt{2\pi}}{2} \left[\hat{f}(0) \hat{f}\left(\frac{\pi}{L}\right) \dots \hat{f}\left(\left(\frac{N}{2} - 1\right) \frac{\pi}{L}\right) \hat{f}\left(-\frac{N}{2} \frac{\pi}{L}\right) \dots \hat{f}\left(-\frac{\pi}{L}\right) \right]^t.$$

O cálculo da DTF tem um custo computacional de N^2 produtos, contudo, este processo pode ser otimizado para um custo de $N \log N$ produtos com a utilização do algoritmo FFT (OPPENHEIN; SCHAFER, 1974).

Para maior aprofundamento matemático, existe uma extensa quantidade de obras que tratam das características da transformada de *Fourier*. Na sua forma contínua, pode-se consultar textos como (SNEDDON, 1995; SPIEGEL, 1974), já em sua forma discreta, as principais obras são (BLAHUT, 1985; NUSSBAUMER, 1981).

A DFT tem grande aplicabilidade nas áreas de ciências e engenharias. Neste trabalho será utilizada a sua forma rápida, FFT, para a análise do sinal sEMG. A FFT permite a identificação de parâmetros do sinal sEMG como a relação entre baixas e altas frequências a partir da frequência mediana do espectro de potência (OPPENHEIN; SCHAFER, 1974). A implementação da FFT será através da biblioteca *NumPy* da linguagem de programação *Python*.

2.3 APRENDIZADO DE MÁQUINA

O AM pode ser dividido em 3 tipos: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço (RASCHKA, 2015).

2.3.1 Aprendizado Supervisionado

O aprendizado supervisionado busca aprender um modelo a partir de dados de treinamento rotulados, permitindo fazer previsões de dados não conhecidos ou futuros. No que tange o aprendizado supervisionado, tem-se outras duas subdivisões, a classificação e a regressão.

A classificação é caracterizada por tarefas de aprendizado com rótulos distintos, onde o seu objetivo é prever os rótulos de classes de novas instâncias a partir do treinamento com rótulos de instâncias conhecidas anteriormente. A tarefa de classificação por ser binária, no caso em que o AM distingue duas classes possíveis: paciente com PD ou paciente saudável. Contudo, a tarefa de classificação pode ser mais complexa possuindo várias classes. Neste caso, o algoritmo de AM pode prever com uma certa precisão qualquer classe que tenha feito parte do seu conjunto de treinamento, por exemplo: classificar diferentes níveis de estadiamento da DP (RASCHKA, 2015; BISHOP, 2006; HENRIK; RICHARDS; FETHEROLF, 2016; GOLLAPUDI, 2016).

A regressão é utilizada quando o objetivo é prever resultados contínuos. Na regressão, é definido um conjunto de variáveis preditoras e uma variável de resposta contínua e, através de uma correlação entre essas variáveis o algoritmo de AM é capaz de realizar a predição da variável contínua (RASCHKA, 2015).

2.3.2 **Aprendizado Não Supervisionado**

O aprendizado não supervisionado lida com dados não rotulados ou com uma estrutura desconhecida. Com técnicas de aprendizado não supervisionado é possível explorar estruturas de dados e extrair informações significativas sem a necessidade do conhecimento de um rótulo de classe ou uma função de recompensa (RASCHKA, 2015; BISHOP, 2006).

Na área do aprendizado não supervisionado podem ser destacadas duas subáreas: a clusterização e a redução de dimensionalidade. A clusterização é uma técnica exploratória de análise de dados que nos permite organizar uma pilha de informações em subgrupos significativos (*clusters*) sem ter nenhum conhecimento prévio de suas associações a grupos. Enquanto a redução de dimensionalidade é uma abordagem amplamente utilizada no pré-processamento de recursos para remover os ruídos dos dados, que por sua vez pode atenuar o desempenho preditivo e compactar os dados em um subespaço dimensional menor, mantendo a maioria das informações relevantes (RASCHKA, 2015).

2.3.3 **Aprendizado Por Reforço**

Outro tipo de AM é o aprendizado por reforço. Na aprendizagem de reforço, o objetivo é desenvolver um sistema (agente) que melhore seu desempenho com base nas interações com o ambiente. Como as informações sobre o estado atual do ambiente normalmente também incluem um chamado sinal de recompensa para cada classificação realizada corretamente. Pode-se pensar no aprendizado por reforço como um campo relacionado ao aprendizado supervisionado. No entanto, no aprendizado por reforço, esse *feedback* não é o rótulo ou valor correto da verdade básica, mas uma medida de quão bem a ação foi medida por uma função de recompensa. Por meio da interação com o ambiente, um agente pode usar o aprendizado por reforço para aprender uma série de ações que maximizam essa recompensa por meio de uma abordagem exploratória de tentativa e erro ou planejamento deliberativo (RASCHKA, 2015).

2.3.4 **Random Forest**

Random forest é uma combinação de árvores de preditores, onde cada árvore depende dos valores de um vetor aleatório amostrado de forma independente e com a mesma distribuição para todas as árvores na floresta. Quando o número de árvores se torna grande o bastante, o erro de generalização converge para um limite. Basicamente, o método *random forest* gera um conjunto de árvores de decisão dentro de cada objeto, onde cada um des-

ses objetos passa por um mecanismo de votação (*bagging*) e, então, o elege a classificação mais votada. A classificação é obtida nos nós das árvores de decisão (RASCHKA, 2015; HASTIE; TIBSHIRANI, 2008). Na Figura 3 se pode observar um exemplo de aplicação de árvores de decisão para classificação de três classes, onde, iniciou-se com 105 amostras na raiz e dividiu-se em dois nós com 34 e 71 amostras. Após a primeira divisão, o nó da esquerda já está “puro” com amostras apenas da primeira classe. Em seguida, novas divisões são feitas até atingir os parâmetros pré-configurados do algoritmo, como número de divisões e entropia/impureza máxima.

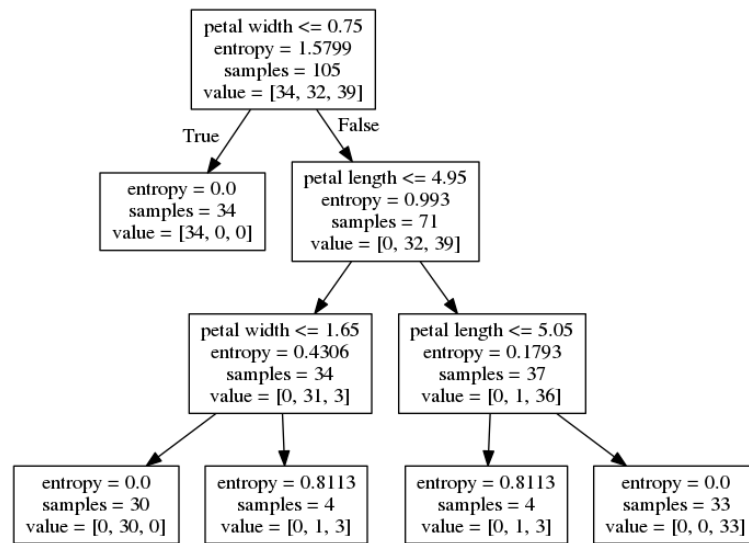


Figura 3 – Exemplo de árvore de decisão (RASCHKA, 2015).

2.3.5 *Support Vector Machine*

O *Support Vector Machine* (SVC) é um classificador de alto desempenho em grandes espaços dimensionais. Onde, para se tratar um problema não linear, o conjunto de dados para treinamento é transformado em um maior espaço dimensional através de uma função de mapeamento, tornando o conjunto de dados linearmente separável. Em seguida, procura-se um hiperplano no espaço de dados de forma que a margem entre o hiperplano e as classes sejam maximizadas (RASCHKA, 2015; HASTIE; TIBSHIRANI, 2008). Para a função de mapeamento foram utilizados os *Kernels Radial Basis* e *Polynomial Kernel functions*, que são definidos como:

Polynomial kernel:

$$k(x^{(i)}, x^{(j)}) = (x^{(i)T}x^{(j)} + \theta)^p, \quad (4)$$

em que, k é a matriz de similaridade (Kernel), x é o vetor de características, θ é o limiar e p é a potência que deve ser especificada pelo usuário.

Kernels Radial Basis (RBF):

$$k(x^{(i)}, x^{(j)}) = \exp\left(-\gamma \|x^{(i)} - x^{(j)}\|^2\right), \quad (5)$$

em que, γ é o parâmetro de ajuste do kernel RBF

2.3.6 *K-Nearest Neighbors*

K-Nearest Neighbors (KNN) é um algoritmo de classificação que pertence a uma subcategoria de modelos não paramétricos baseados em aprendizado por instância. Este tipo de algoritmo é caracterizado como um "aprendiz preguiçoso", pois, memoriza conjuntos de treinamentos ao invés de aprender uma função discriminativa dos dados de treinamento. KNN é associado também a custo "zero" durante o processo de aprendizado (RASCHKA, 2015).

O algoritmo KNN pode ser simplificado em três passos:

1. Escolher o número k e a métrica de distância;
2. Encontrar os k vizinhos mais próximos da amostra que deve ser classificada;
3. Atribuir o rótulo da classe por maioria de votos.

A Figura 4 exemplifica a classificação por maioria de votos.




Figura 4 – Atribuição de classe por maioria de votos. Adaptado de (RASCHKA, 2015)

Uma grande vantagem do KNN é sua capacidade de se adaptar imediatamente conforme novos dados de treinamento são coletados. Como desvantagem, pode ser citado

o aumento linear da complexidade computacional para classificar novas amostras quando cresce o número de amostras no conjunto de pior caso e em conjuntos de muitas dimensões. Para garantir o ótimo desempenho do algoritmo, a escolha ideal de k é muito importante, de forma que se atinja um equilíbrio entre *over-* e *underfitting*. Outro fator importante, é a escolha da métrica de distância. Usualmente é utilizado uma medida de distância Euclidiana simples para casos de amostras com valores reais. Contudo, a normalização dos dados é essencial para que todas as características contribuam com o mesmo peso para o cálculo da distância (RASCHKA, 2015). Outras métricas de distância podem ser utilizadas como “*Manhattan*” por exemplo.

A Equação 6 generaliza as distâncias Euclidiana e *Manhattan*:

$$d(x^{(i)}, x^{(j)}) = \sqrt[p]{\sum_k |x_k^{(i)} - x_k^{(j)}|^p}. \quad (6)$$

onde, para $p = 2$ temos a distância Euclidiana e para $p = 1$ temos da distância *Manhattan*.

2.4 ANÁLISE ESTATÍSTICA

2.4.1 Matriz de Confusão

A matriz de confusão é uma matriz ou tabela de valores reais e valores preditos que descrevem o desempenho do seu classificador. Cada valor ou classe predita é comparado com sua classe real e, então, tem-se quantas amostras foram classificadas erroneamente e quantas estavam corretas (JOSHI, 2017; SUSMAGA, 2011). A partir da matriz de confusão é possível extrair diversas métricas importantes no campo de AM, como:

$$Acurácia = \frac{TP + TN}{TP + FP + TN + FN}. \quad (7)$$

$$Sensibilidade = \frac{TP}{TP + FN}. \quad (8)$$

$$Especificidade = \frac{TN}{TN + FP}. \quad (9)$$

$$Precisão = \frac{TP}{TP + FP}. \quad (10)$$

onde, TP é o número de positivos verdadeiros, i.e., um voluntário do grupo controle é classificado como não parkinsoniano; TN é o número de negativos verdadeiros; FP é o número de falsos positivos; FN é o número de falsos negativos; *Sensibilidade* é a proporção de verdadeiros positivos: a capacidade do sistema em prever corretamente a condição

para casos em que realmente a têm; *Precisão* é a proporção de verdadeiros positivos em relação a todas as predições positivas; *Especificidade* é a proporção de verdadeiros negativos: a capacidade do sistema em prever corretamente a ausência da condição para casos em que realmente não a têm; e, *Acurácia* é a proporção de predições corretas, sem levar em consideração o que é positivo e o que é negativo (SUSMAGA, 2011; VISA et al., 2011).

Outra métrica muito importante na avaliação de classificadores supervisionados é a área sob Curva ROC (do inglês *Receiver Operating Characteristic*) (HAND; TILL, 2001). A curva ROC é formada pela taxa de verdadeiros positivos (no eixo das abscissas) e pela taxa de falsos positivos (no eixo das ordenadas). Na Figura 5 podemos observar um classificador perfeito, linha verde, um classificador aleatório, linha vermelha e um classificador considerado bom, linha azul. Na prática, classificadores considerados bons estarão entre a linha diagonal e a linha perfeita, onde quanto maior a distância da linha diagonal, melhor o sistema (PRATI; BATISTA; MONARD, 2008).

A partir de então, obtêm-se a área sob a curva ROC (AUC - do inglês *Area Under the Curve*), área cinza na Figura 5.




Figura 5 – Curva ROC

2.4.2 *Principal Components Analysis*

Principal Components Analysis (PCA) é uma técnica estatística útil para encontrar padrões em dados de alta dimensão. Esta técnica identifica padrões em dados e expressa os dados de forma a destacar suas semelhanças e diferenças. Como os padrões nos dados podem ser difíceis de encontrar em dados de alta dimensão, onde o luxo da representação gráfica não

está disponível, o PCA é uma ferramenta poderosa para analisar dados (KREYZIG, 2011; BISHOP, 2006). Outra vantagem do PCA é que, depois de ter encontrado esses padrões nos dados, é possível compactar os dados, ou seja, reduzir o número de dimensões, sem muita perda de informação. Esta técnica pode ser usada por exemplo, na compressão das características dos dados, reduzindo consideravelmente o volume de dados a serem processados e o custo de treinamento dos algoritmos (KREYZIG, 2011; BISHOP, 2006). Basicamente o PCA pode ser resumido nos seguintes passos:

- Obter algum banco de dados;
- Subtrair a média de cada uma das dimensões de dados;
- Calcular a matriz de covariância;
- Calcular os autovalores e autovetores da matriz de covariância;
- Escolher componentes e formar um vetor de característica;
- Gerar o novo conjunto de dados através da transposição do vetor de características e multiplicação à esquerda do conjunto de dados original, transposto.

3 METODOLOGIA

Este trabalho foi dividido em etapas, tais como: definição de protocolo, coleta de dados, tratamento dos dados, implementação de filtros e algoritmos, testes e validação. O fluxograma das etapas pode ser observado na Figura 6.

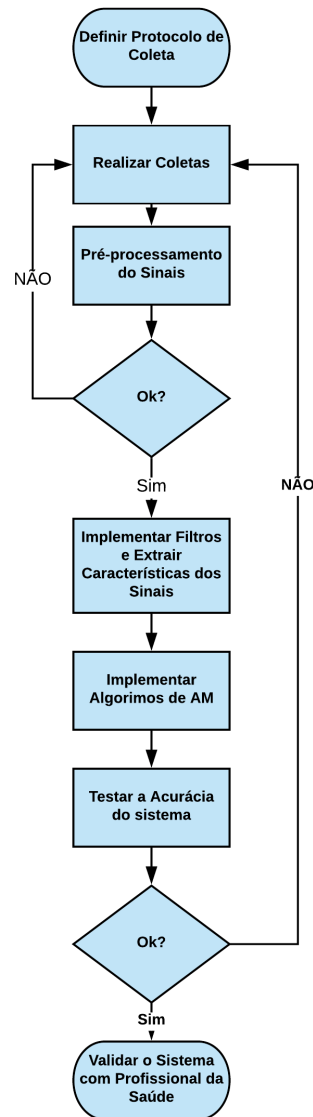


Figura 6 – Fluxograma de desenvolvimento da pesquisa.

3.1 COLETA E ANÁLISE DE DADOS

Os dados utilizados neste trabalho foram extraídos de sinais sEMG. Os sinais sEMG foram coletados em voluntários na Associação de Parkinson de Brasília (APB) e no Centro Comunitário do Idoso Luiza Marilac (CCILM) com a utilização do Eletromiógrafo *Miotool*

Tabela 3 – Perfis dos voluntários Parkinsonianos.

PD	Idade	Sexo	Altura (m)	Peso (Kg)	H-Y
1	50	M	1,66	96	1,5
2	60	M	1,73	65	1
3	61	M	1,70	67	1,5
4	67	M	1,87	73	1,5
5	65	M	1,75	80	1
6	80	M	1,75	76	2
7	60	M	1,64	74	3
8	82	M	1,76	78	1,5
9	76	M	1,67	47	4
10	66	M	1,66	59	1,5
11	62	M	1,72	73	1
12	69	M	1,61	81	1,5
13	81	F	1,49	78	1
14	67	M	1,78	94	1
15	55	F	1,60	55	2
16	73	M	1,73	77	1
17	73	M	1,77	82	1
18	51	M	1,65	78	2
19	70	F	1,50	55	1
20	65	M	1,66	67	3
21	60	F	1,56	73	1
22	65	M	1,63	84	1,5
23	80	M	1,56	66	1
24	70	M	1,78	91	4
25	58	F	1,62	51	2,5
26	65	F	1,54	62	1
27	81	M	1,77	85	1
28	50	M	1,75	88	2
29	69	M	1,69	65	3
30	73	M	1,75	79	1

(*Miotec*[®] - ilustrado na Figura 7). As coletas foram realizadas entre os meses de outubro à dezembro de 2017, de fevereiro a abril de 2018 e de agosto a outubro de 2018. Os voluntários foram contactados diretamente na APB e no CCILM, durante seus encontros semanais, por meio de palestra explicativa do projeto. Na primeira fase da pesquisa, a amostra foi composta por dados de 30 voluntários Parkinsonianos fora do período de efeito de medicações para DP (chamado de período *off*) e 20 voluntários do grupo controle. Os perfis dos voluntários Parkinsonianos e do grupo controle podem ser observados nas Tabelas 3 e 4, respectivamente. Para as coletas foi definido um protocolo onde foram estabelecidas diretrizes que possibilitaram a obtenção de dados com a maior relevância de informação para a classificação do estagiamento da DP.

Esta pesquisa foi aprovada pelo Comitê de Ética e Pesquisa (CEP) da Faculdade da Saúde (FS) da UnB com o Certificado de Apresentação para Apreciação Ética (CAAE)

Tabela 4 – Perfis dos voluntários do grupo controle.

Quantidade de voluntários	Idade	Sexo	Altura (m)	Peso (Kg)
20	74 ± 12	M=6 / F=14	1,60 ± 0,155	71 ± 21

de número 66951316.0.0000.0030.



Figura 7 – Eletromiógrafo *Miotool* utilizado para coleta dos sinais sEMG (MIOTEC, 2017).

3.1.1 Protocolo para Coleta de Sinais sEMG

Este protocolo foi estabelecido com base no protocolo do projeto SENIAM (sigla em inglês para *Surface Electromyography for the Non-Invasive Assessment of Muscles* - Eletromiografia de Superfície para a Avaliação de Músculos), que visa padronizar as metodologias de coletas entre diversos grupos, uma vez que o uso de sEMG ocorre de forma dispersa em grupos ao redor do mundo (SENIAM, 1999).

Inicialmente, este protocolo foi composto por idosos acima de 50 anos, lúcidos e orientados no espaço e tempo, sem problemas circulatórios complexos, sem histórico de outras alterações neurológicas com sistema osteomioarticular intacto. O grupo experimental devia abranger indivíduos portadores da doença de Parkinson, sem outra doença neurodegenerativa, praticantes ou não de atividades físicas. Cada paciente necessitou comparecer ao local uma vez, ou seja, um encontro.

No início do procedimento foi apresentado ao voluntário o Termo de Consentimento Livre e Esclarecido (TCLE) Anexo A e alguns questionários definidos pelo grupo. A ordem foi a seguinte:

- Assinatura do TCLE por parte do voluntário;
- Ficha de dados pessoais criada pelo grupo de pesquisa;
- Estadiamento da doença nas escalas H-Y;
- Coleta dos sinais sEMG.

Foram selecionados os músculos: extensor radial do longo do carpo, flexor superficial dos dedos, bíceps braquial e flexor radial do carpo. A escolha destes grupos musculares foi com base na observação dos pesquisadores em quais grupos musculares são mais requisitados durante os tremores e também foi levado em conta o grupos de maior facilidade para captação dos sinais sEMG. Então, a partir destes grupos musculares coletou-se os sinais de diferentes tipos de tremores, como: tremor de repouso, tremor isométrico, tremor de ação e tremor de intenção.

Para o posicionamento dos eletrodos foi solicitado que o voluntário permanecesse em posição de sedestação ao invés de decúbito, pois essa posição mantém o tronco ereto, tendo em vista que o paciente passará a maior parte do encontro nessa posição. Em seguida foi realizada a tricotomia utilizando aparelho de barbear descartável, algodão e álcool 70%, assim como recomendado pelo autor SENIAM (1999). Após a limpeza da área de coleta foram posicionados 8 eletrodos abaixo do ponto motor de cada músculo de interesse mantendo a distância intereletrodo de 20 mm, conforme indicado por (SENIAM, 1999). A Crista Ilíaca direita foi utilizada como local para o eletrodo de referência. Todo o procedimento levou entre 15 e 20 minutos.

3.1.2 Coleta 1 - Tremor de Repouso

Foi solicitado que o voluntário permaneça em sedestação com as mãos sobre o colo de forma relaxada. Foram realizadas três coletas com duração de 5 segundos cada de forma bilateral e com a utilização de 4 canais. Houve um intervalo de 30 segundos entre as coletas. Os grupos musculares utilizados nesta atividade foram:

- Extensor radial do longo do carpo direito;
- Flexor superficial dos dedos direito;
- Extensor radial do longo do carpo esquerdo;
- Flexor superficial dos dedos esquerdo.

Na Figura 8 pode-se observar a disposição dos eletrodos nas marcações em verde.




Figura 8 – Posicionamento de eletrodos para captação de tremores de repouso (MIOTEC, 2017).

3.1.3 Coleta 2 - Tremor Isométrico

Foi solicitado que o voluntário permanece em sedestação com as mãos cerradas sobre o colo. São realizadas três coletas com duração de 5 segundos cada de forma bilateral e com a utilização de 4 canais. Houve um intervalo de 30 segundos entre as coletas. Os grupos musculares utilizados nesta atividade são:

- Extensor radial do longo do carpo direito;
- Flexor superficial dos dedos direito;
- Extensor radial do longo do carpo esquerdo;
- Flexor superficial dos dedos esquerdo.




Figura 9 – Posicionamento de eletrodos para captação de tremores isométrico (MIOTEC, 2017).

Na Figura 9 pode-se observar a disposição dos eletrodos nas marcações em verde.

3.1.4 Coleta 3 - Tremor de Ação

Foi solicitado que o voluntário permanece em sedestação com as mãos sobre o colo. Uma garrafa vazia é entregue ao voluntário e então o voluntário realiza o movimento de levar a garrafa até a boca e retorna ao colo 3 vezes. Este processo deve ser repetido 3 vezes com cada um dos lados (de forma unilateral) e com a utilização de 3 canais. Houve um

intervalo de 30 segundos entre as coletas. Os grupos musculares utilizados nesta atividade são:

- Extensor radial do longo do carpo direito;
- Flexor superficial dos dedos direito;
- Bíceps braquial direito;
- Extensor radial do longo do carpo esquerdo;
- Flexor superficial dos dedos esquerdo;
- Bíceps braquial esquerdo.




Figura 10 – Posicionamento de eletrodos para captação de tremores de ação (MIOTEC, 2017).

Na Figura 10 pode-se observar a disposição dos eletrodos nas marcações em verde.

3.1.5 Coleta 4 - Tremor de Intenção

Foi solicitado que o voluntário permaneça em sedestação com o ombro em abdução de 90 graus e dedo indicador estendido. Então é instruído ao voluntário que ele alcance o seu nariz com o seu dedo indicador e, em seguida retorne sua mão para a posição inicial 3 vezes. Este processo deve ser repetido 3 vezes com cada um dos lados (de forma unilateral) e com a utilização de 4 canais. Houve um intervalo de 30 segundos entre as coletas. Os grupos musculares utilizados nesta atividade são:

- Extensor radial do longo do carpo direito;
- Flexor superficial dos dedos direito;
- Bíceps braquial direito;
- Flexor radial do carpo direito;
- Extensor radial do longo do carpo esquerdo;

- Flexor superficial dos dedos esquerdo;
- Bíceps braquial esquerdo;
- Flexor radial do carpo esquerdo.




Figura 11 – Posicionamento de eletrodos para captação de tremores de intenção (MIO-TEC, 2017).

Na Figura 11 pode-se observar a disposição dos eletrodos nas marcações em verde.

Após o término das coletas todos os materiais descartáveis foram eliminados de forma segura e apropriada com a utilização de caixas coletora rígida estanque.

3.1.6 Extração de Características

Antes dos sinais serem processados pelo sistema, eles são convertidos do formato *European Data Format* (EDF) para o *NumPy Data File* (NPY) através da biblioteca *NumPy* da linguagem de programação *Python*. O formato NPY foi escolhido devido a sua sofisticação e seu alto desempenho no processamento de dados. Este formato permite também a fácil remoção dos dados pessoais dos voluntários, preservando assim a sua identidade.

Após a conversão dos sinais e a remoção dos dados pessoais, cada arquivo é segmentado e removido 1 segundo do início e do final de cada amostra. Dessa forma, são eliminados possíveis ruídos gerados por atraso próprio do sistema do eletromiógrafo na captura e gravação dos dados. Esta segmentação permite também o redimensionamento das amostras para que todas fiquem com o mesmo tamanho e, assim ser possível realizar operações matriciais.

Para extração de características dos sinais previamente segmentados, este trabalho propôs o modelo de concatenação de características junto à técnica de PCA. Este modelo foi escolhido devido a sua capacidade de extrair características hierárquicas robustas, reduzindo a dimensionalidade e otimizando as características necessárias para posterior classificação do estadiamento da DP em cada amostra.

Inicialmente, utilizou-se 4 técnicas para extrair as características dos sinais, dentre elas, normalização, raiz do valor quadrático médio ou RMS (Root Mean Square), FFT

e filtros digitais (Passa-baixas e Passa-faixas). As extrações foram implementadas com o uso das bibliotecas *NumPy*, *SciPy* e *Pandas* da linguagem de programação *Python*. Essas características foram concatenadas formando um bloco de dados o qual foi submetido ao algoritmo PCA formando um novo bloco de dimensão reduzida. Este último bloco foi dividido em 3 subgrupos, um para treinamento dos algoritmos de AM, um para teste e um para validação, conforme sugere a literatura (RASCHKA, 2015).

3.1.7 Classificação de Características

Para a classificação das características extraídas na etapa anterior, este trabalho faz o uso de três algoritmos de classificação. sendo eles: *Random Fores*, *SVM-RBF* e *SVM-Poly*. Estes modelos foram escolhidos devido as suas capacidades de classificar dados não lineares com alto desempenho.

A parametrização de cada um desses modelos foi realizada através de uma busca empírica em um intervalo de parâmetros. Essa busca foi realizada com a ferramenta *Grid-Search*. Em seguida, os modelos foram validados através da técnica de validação cruzada K-fold. Na Tabela 5 estão disposto os intervalos de parâmetros utilizados em cada modelo

Tabela 5 – Intervalo de parâmetros utilizados.

Classificador	Parâmetro	Valores
<i>Random Forest</i>	<i>n_estimators</i>	100, 300, 500, 1, 10
	<i>criterion</i>	<i>gini</i> , <i>entropy</i>
	<i>obb_score</i>	<i>True</i> , <i>False</i>
<i>SVM-RBF</i>	<i>gamma</i>	0.0001, 0.0005, 0.001, 0.005, 0.01, 0.1, 0.2, 0.3, 0.5
	<i>C</i>	0.001, 0.01, 0.05, 0.1, 0.5, 1, 3, 6, 8, 10, 30 40, 50, 70, 80, 90, 100
	<i>decision_function_shape</i>	<i>ovo</i> , <i>ovr</i>
	<i>degree</i>	3, 4, 5, 6
	<i>coef</i>	1, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0, 4.5, 5.0, 5.5, 6.0, 6.5, 7.0, 7.5, 8.0
<i>SVM-Poly</i>	<i>C</i>	0.001, 0.01, 0.05, 0.1, 0.5, 1, 1.5, 3, 6, 8, 10, 20, 30, 50, 100
	<i>decision_function_shape</i>	<i>ovo</i> , <i>ovr</i>

A implementação dos classificadores (criação, treinamento e validação) foi por meio da linguagem de programação *Pyhon* e da biblioteca *Scikit-learn*.

3.1.8 Análise de Desempenho

Por fim, para analisar o desempenho do sistema, foi aplicada a matriz confusão, da qual derivou-se as métricas descritas nas Equações (7), (8), (9) e (10), e também o cálculo da AUC. Para implementação da matriz confusão foi utilizada a biblioteca *Scikit-learn* da

linguagem *Python*, para o cálculo das métricas de desempenho foram utilizadas funções e operações matemáticas nativas da linguagem *Python*. Na Figura 12 pode ser observado as etapas de extração de características dos sinais e implementação dos algoritmos de AM.

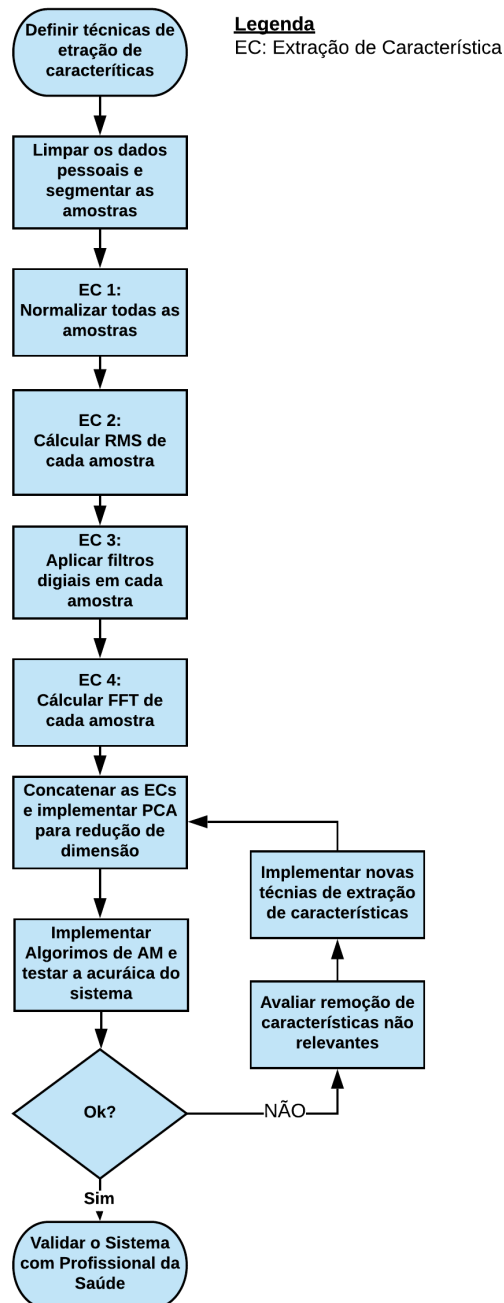


Figura 12 – Etapas da extração de características.

3.2 INTERFACE DE OPERAÇÃO DO USUÁRIO

Para facilitar a utilização do sistema por um usuário da área da saúde foi utilizada a própria plataforma de desenvolvimento da linguagem de programação *Python*. A pro-

gramação dos códigos foi modelada de modo que o usuário precisasse apenas copiar os arquivos de amostras a serem classificados para pasta do classificador e clicar na opção *Reset & Run All* na interface do usuário. O Apêndice A apresenta uma imagem da interface e as diretrizes de como inicializar o sistema de classificação.

3.3 DELIMITAÇÃO DO ESTUDO

O sistema aqui proposto visa o auxílio de especialistas da área da saúde na classificação/estadiamento da DP. O sistema foi desenvolvido para ser dinâmico, sendo capaz de operar com sinais sEMG dos eletromiógrafos mais comuns no mercado, sem a necessidade de interação humana para o pré processamento.

3.4 RECURSOS TECNOLÓGICOS

O sistema foi desenvolvido nos sistemas operacionais *Linux Mint Cinnamon 18.3* e *Windows 10*, utilizando linguagem *Python* na versão 2.7.13. Foram também utilizadas as bibliotecas *NumPy* versão 1.12.1, *Scikit-Learn* versão 0.19 e *SciPy* versão 0.19.1. Também foram utilizados no desenvolvimento um *notebook* (com processador *Intel®Core™ i5-72000 @ 2.50GHZ × 2, 8GB* de memória *RAM* e *SSD* de *500GB*) e um *desktop* (com processador *Intel®Core™ i5-4690K @ 3.50GHZ × 4, 8GB* de memória *RAM* e *SSD* de *256GB*).

Foi utilizado o eletromiógrafo *Miotool* (comprado com o auxílio financeiro da FAP-DF - processo 0193.000860 /2015) para a realização das coletas dos sinais sEMG.

3.5 RESTRIÇÕES

É necessário o cuidado especial com dados pessoais de pacientes presentes nos arquivos dos sinais sEMG coletados e gerados pela aplicação *MiotecSuite* versão 1.0.

4 RESULTADOS

4.1 CLASSIFICAÇÃO DOS NÍVEIS DE ESTADIAMENTO DA DOENÇA DE PARKINSON

A implementação dos algoritmos de AM, do processamento de sinais, da extração de características e as análises estatísticas foram concluídos utilizando a linguagem de programação *Python* versão 2.7. A implementação é capaz de aceitar sinais sEMG de diversos tipos de eletromiógrafos, uma vez que, grande parte dos eletromiógrafos comerciais utilizam formatos manipuláveis pela linguagem *Python* para gravar os seus dados. No atual estágio da pesquisa, o usuário também pode configurar os parâmetros dos algoritmos a fim de otimizar o desempenho do sistema para o mais generalista possível.

4.1.1 Treinamento SVM-RBF

Para o treinamento do algoritmo SVM-RBF foram utilizados os parâmetros: *kernel='rbf'*, *gamma=0.2*, *C=6* e *decision_function_shape='ovr'*. Este processo levou aproximadamente 40 minutos para o treinamento e 8 minutos para predição. Na Figura 13, temos a matriz de confusão resultante, onde, no eixo das ordenadas temos os Valores reais e no eixo das abscissas os Valores preditos.




Figura 13 – Matriz de Confusão SVM-RBF.

A partir dos dados obtidos gerados pela matriz de confusão foram calculadas as métricas de desempenho, dispostas na Tabela 6, e também as curvas ROC de cada classe e suas respectivas AOC para o auxílio na avaliação de desempenho do algoritmo. As curvas ROC e as AOC observadas na Figura 14.

Tabela 6 – Métricas SVM-RBF.

Classificador	Classe	Métricas de desempenho		
		Sensibilidade	Precisão	Acurácia
RF	N-1	15,11 %	38,69 %	36,80 %
	N-2	30,37 %	83,14 %	
	N-3	74,15 %	26,54 %	
	N-4	45,62 %	22,10 %	




Figura 14 – Curva ROC SVM-RBF.

4.1.2 Treinamento SVM-Poly

Para o treinamento do algoritmo SVM-Poly foram utilizados os parâmetros: $kernel='poly'$, $degree=4$, $coef0=4.7$, $C=48.9$ e $decision_function_shape='ovr'$. Este processo levou aproximadamente 120 horas para o treinamento e 40 minutos para predição. Na Figura 15, temos a matriz confusão resultante, onde, no eixo das ordenadas temos os Valores reais e no eixo das abscissas os Valores preditos.




Figura 15 – Matriz de Confusão SVM-Poly.

A partir dos dados obtidos gerados pela matriz de confusão foram calculadas as métricas de desempenho, dispostas na Tabela 7, e também as curvas ROC de cada classe e suas respectivas AOC para o auxílio na avaliação de desempenho do algoritmo. As curvas ROC e as AOC observadas na Figura 16.

Tabela 7 – Métricas SVM-Poly.

Classificador	Classe	Métricas de desempenho		
		Sensibilidade	Precisão	Acurácia
SVB-Poly	1	94,87%	47,76 %	45,01 %
	2	4,64 %	32,83 %	
	3	36,41 %	74,42 %	
	4	27,67 %	67,58 %	

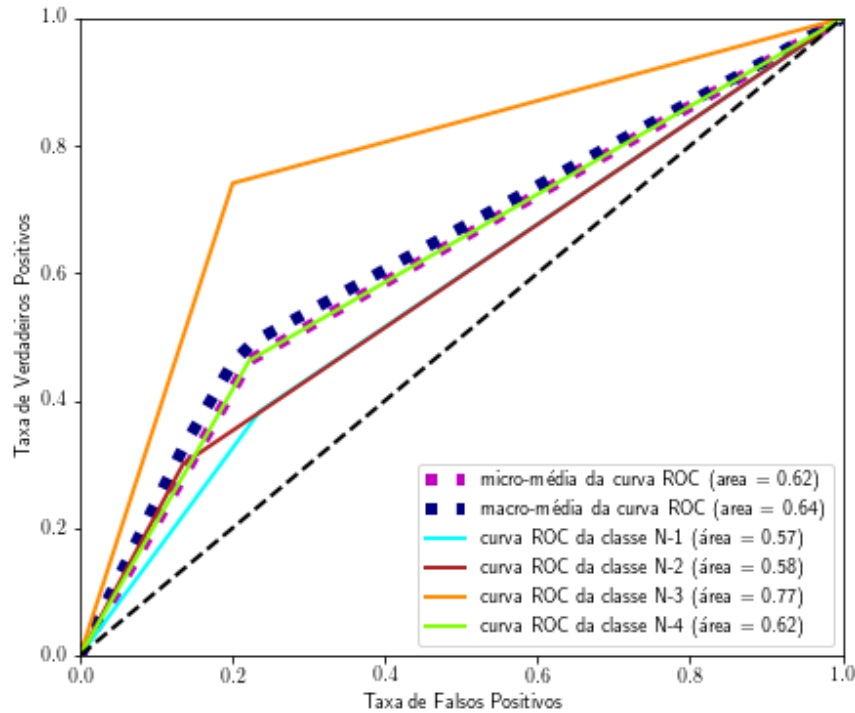


Figura 16 – Curva ROC SVM-Poly.

4.1.3 Treinamento RF

Para o treinamento do algoritmo RF foram utilizados os parâmetros: $n_estimators=1000$, $criterion='entropy'$, $oob_score=True$ e $n_jobs=4$. Este processo levou aproximadamente 3 minutos para o treinamento e 2 segundos para predição. Na Figura 17, temos a matriz confusão resultante, onde, no eixo das ordenadas temos os Valores reais e no eixo das abscissas os Valores preditos.

A partir dos dados obtidos gerados pela matriz de confusão foram calculadas as métricas de desempenho, dispostas na Tabela 8, e também as curvas ROC de cada classe e suas respectivas AOC para o auxílio na avaliação de desempenho do algoritmo. As curvas ROC e as AOC observadas na Figura 18.

Tabela 8 – Métricas RF.

Classificador	Classe	Métricas de desempenho		
		Sensibilidade	Precisão	Acurácia
RF	N-1	54,63 %	57,02 %	61,47 %
	N-2	73,42 %	62,52 %	
	N-3	52,93 %	65,87 %	
	N-4	57,76 %	54,29 %	




Figura 17 – Matriz de Confusão SVM-RF.




Figura 18 – Curva ROC RF.

4.1.4 Treinamento KNN

Para o treinamento do algoritmo KNN foram utilizados os parâmetros: $n_neighbors=100$, $weights='distance'$, $leaf_size=60$, $n_jobs=4$ e $p=4$. Este processo levou aproximadamente 1 minuto para o treinamento e 5 minutos para predição. Na Figura 19, temos a matriz de confusão resultante, onde, no eixo das ordenadas temos os Valores reais e no eixo das abscissas os Valores preditos.




Figura 19 – Matriz de Confusão KNN.

A partir dos dados obtidos gerados pela matriz de confusão foram calculadas as métricas de desempenho, dispostas na Tabela 9, e também as curvas ROC de cada classe e suas respectivas AOC para o auxílio na avaliação de desempenho do algoritmo. As curvas ROC e as AOC observadas na Figura 20.

Tabela 9 – Métricas KNN.

Classificador	Classe	Métricas de desempenho		
		Sensibilidade	Precisão	Acurácia
KNN	N-1	49,28 %	50,03 %	52,98 %
	N-2	73,39 %	53,37 %	
	N-3	39,46 %	62,57 %	
	N-4	49,33 %	49,29 %	




Figura 20 – Curva ROC KNN.

4.1.5 Validação do Sistema Pelo Profissional da Saúde

A validação do sistema foi realizado no Laboratório de Biofísica e Fisiologia do Exercício da UnB-FCE. Todo o procedimento foi realizado por um profissional da saúde com a colaboração de três voluntários portadores da DP, dois em nível 1 e um no nível 3 na escala H-Y. Esta validação foi supervisionada pelo autor deste trabalho para o caso do surgimento de possíveis dúvidas ou dificuldades técnicas na execução do sistema de classificação. A validação percorreu as seguintes etapas:

- Estadiamento da DP do voluntário de acordo com a escala H-Y;
- Aplicação do protocolo de coleta de sinais sEMG;
- Transferência dos dados coletados para a pasta do sistema de classificação;
- Execução do sistema de classificação;
- Comparação entre a resposta do sistema de classificação e a classificação realizada pelo profissional da saúde.

Na Figura 21 é possível observar, de forma resumida, como o sistema apresenta seus resultados. É gerado um relatório com os gráficos das características extraídas dos

sinais sEMG coletados. Para visualizar o relatório completo, ver o Apêndice B. Consta também no relatório completo, um quadro com a probabilidade de que nível a amostra utilizada pertence. Neste exemplo de classificação foram utilizadas amostras de um voluntário estratificado como nível 3 na escala H-Y.

Relatório

ModeloFinal

September 27, 2018

```
In [1]: %matplotlib inline
        from preProcessing import *
        from processing import *

In [2]: preProcessing()
```




Figura 21 – Resumo do relatório gerado pelo sistema.

4.1.6 Produção Intelectual

Durante o percurso de desenvolvimento deste trabalho foram estudadas diversas técnicas, metodologias, realização de revisões e aplicação do conhecimento adquirido. Com isso, foi possível o desenvolvimento de trabalhos paralelos, que por sua vez, puderam ser expressados como artigos de eventos e periódicos. Na Tabela 10 estão relacionados os artigos publicados e os que ainda se encontram em fase de análise pelos revisores. Os artigos já publicados se encontram na sessão de Apêndices, conforme indicado na Tabela 10.

Tabela 10 – Artigos produzidos.

Periódico Evento	Título	Status	Apêndice
Congresso: COBEC 2017	Classificação do potencial de ação muscular através de técnicas de aprendizagem de máquinas aplicadas a sEMG	Publicado	C
Congresso: COBEC 2017	Classificação de padrões de marcha utilizando-se de diferentes algoritmos de aprendizado de máquinas	Publicado	D
Congresso: COBEC 2017	Captação do SInal de Eletromiografia do Diafragma	Publicado	E
Congresso: CBEB 2018 / IFMBE	Predicting Knee angles from video: an initial experiment with machine learning	Aceito	F
Periódico: <i>Research on Biomedical Engineering</i>	Gait patterns classification using machine learning	Aguardando resposta final	-
Periódico: <i>Research on Biomedical Engineering</i>	Gamification for Parkinson's disease rehabilitation: an integrative review	Aguardando resposta final	-

Na sessão de anexos constam também os certificados dos artigos publicados, apresentações realizadas e o **prêmio de menção honrosa** de melhor trabalho apresentado no V Congresso Brasileiro de Eletromiografia e Cinesiologia X Simpósio de Engenharia Biomédica de 2017.

5 DISCUSSÃO E CONCLUSÃO

Foi proposto neste trabalho um novo método para classificação dos nível da DP de acordo com a escala H-Y a fim de auxiliar o profissional da saúde no estadiamento da DP e também como ferramenta de acompanhamento da evolução da doença. Todos os dados sEMG utilizados neste trabalho foram coletados em voluntários com a DP em seu período de *off*, de modo a minimizar a influência dos medicamentos utilizados pelos pacientes durante a coleta. Os sinais sEMG dos voluntários Parkinsonianos foram coletados na Associação de Parkinson de Brasília e no Laboratório de Biofísica e Fisiologia do Exercício da FCE - UnB. Os sinais coletados foram de homens e mulheres acima de 50 anos, lúcidos, sem problemas circulatórios complexos, sem histórico de outras alterações neurológicas e com sistema osteomioarticular intacto.

Devido a dificuldade de encontrar voluntários com a DP em todos níveis de estadiamento, optou-se por adotar a escala H-Y simplificada. Foram levados em consideração os níveis 1,2,3 e 4, porém, o nível 5 não foi adotado por falta de voluntários nesse estágio. Durante as coletas realizadas foi utilizada a escala H-Y modificada e para o sistema proposto foi feita a seguinte conversão: amostras estratificadas com nível 1,5 foi considerado como nível 1 e amostras estratificadas com nível 2,5 como nível 2.

Por meio de análises realizadas nas etapas de pré processamento e treinamento dos modelos foram descartadas as coletas de tremores de ação e intensão. Estes sinais sEMG não foram utilizados para o modelo final devido a alta presença de ruídos provenientes da movimentação excessiva dos cabos, que por sua vez, deslocavam os eletrodos gerando ruídos de movimentos. Contudo, estes sinais se mostraram de grande peso para o treinamento da rede em testes realizados com algumas poucas amostras onde não haviam os ruídos de movimento ou onde foi possível remove-los ou filtra-los. Para solucionar este problema, poderia ser utilizado no futuro sensores de captação sEMG sem fio. Assim seria possível modelar um sistema mais robusto e generalista no que diz respeito aos diferentes tipos de tremores.

Os resultados mostraram que a utilização das técnicas de extração de características empregadas (FFT, RMS, sinal normalizado e sinal filtrado) foram capazes de generalizar o problema permitindo a classificação das amostras. Um importante aspecto ainda na etapa de préprocessamento foi a redução de dimensionalidade proporcionada pela técnica PCA. Esta redução de dimensões tornou possível o treinamento dos modelos de forma mais ágil, e o mais importante, sem perda de informação considerável, permitindo assim que os classificadores atingissem melhores resultados.

Para classificar as características extraídas, quatro técnicas de AM foram utiliza-

das: SVM-RBF, SVM-Poly, RF e KNN. Ao observar a matriz identidade dos algoritmos (diagonal da matriz de confusão), nota-se que o algoritmo RF apresenta uma generalização levemente maior que o KNN na classificação das classes. As Tabelas 6,7, 8 e 9 com as métricas de cada algoritmo e as curvas ROC apontam também o melhor desempenho do algoritmo RF comparados aos demais em todas as métricas. Contudo, neste caso específico de classificação, deve-se ater maior atenção à métrica de *precisão*, pois ela retorna o quão exato é a classificação para as amostras positivas, ou seja, os casos classificados em algum nível de Parkinson quando realmente há a doença.

Outro ponto que as matrizes de confusão também chamaram a atenção, foi a baixa capacidade de generalização dos modelos SVM-RBF e SVM-Poly para este tipo de classificação. É provável que, com a disponibilização de mais recurso computacional será possível encontrar os parâmetros ideais para a “sintonização” do algoritmo, uma vez que, o SVM-Poly requer grande capacidade computacional para realizar o seu treinamento (em torno de 120 horas rodando com parâmetros de baixa complexidade).

É notória a inovação desta pesquisa em relação aos trabalhos correlatos citados na revisão da literatura. Uma vez que, trabalhos como os de JOSHI; KHAJURIA; JOSHI (2017), RUONALA et al. (2014), ROBICHAUD et al. (2009) e MEIGAL et al. (2009) tinham apenas o objetivo de classificar se o indivíduo possuía ou não a DP, enquanto aqui, o espectro de classificação foi estendido e aprofundado permitindo classificar o nível da DP, e assim possibilitar análises futuras e acompanhamento evolutivo da doença nos indivíduos. Essas análises podem por exemplo, servirem para acompanhar a reação de voluntários à determinadas drogas ou terapias no tratamento da DP.

Para melhora do desempenho dos classificadores sugere-se a utilização/pesquisa de novas técnicas de extração de características dos sinais sEMG que proporcionem informações mais relevantes para este tipo de problema. Contudo, o mais importante no momento é a realização de novas coletas para aumentar o campo amostral e com isso a generalização dos diferentes níveis de estadiamento.

Ainda há melhoras a serem feitas no sistema. Contudo, com os testes iniciais, é percebido que o sistema adquiriu uma boa generalização em relação aos sinais analisados e pode ajudar especialistas, ainda que apenas no âmbito acadêmico nesse primeiro momento, como consulta ou uma segunda opinião no estadiamento da DP.

O *software* desenvolvido neste trabalho foi inteiramente construído utilizando linguagens e bibliotecas *open-source* e de ponta na área de aprendizado de máquina. Isso propiciou velocidade de prototipagem e testes, além da redução dos custos de desenvolvimento.

6 TRABALHOS FUTUROS

Como trabalhos futuros sugere-se os seguintes itens:

- Treinamento do modelo proposto com mais amostras de cada nível de estadiamento e retroalimentação com sistema de aprendizado semi-supervisionado;
- Desenvolvimento de um kernel para SVM modelado especificamente para tratar sEMG em casos da DP;
- Refinamento do código fonte de modo que possa ser usado técnicas de aprendizado profundo;
- Desenvolvimento de uma interface gráfica completa para o sistema;
- Testes com diferentes técnicas de extração de características dos sinais, como o isolamento de unidades motoras;
- Paralelização das etapas de processamento para treinamento e predição mais rápidos e eficientes.
- Realizar coleta com eletrodos sem fio.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABBRUZZESE, G. et al. Rehabilitation for Parkinson's disease: Current outlook and future challenges. *Parkinsonism and Related Disorders*, Elsevier Ltd, v. 22, p. S60–S64, 2016. ISSN 18735126. Disponível em: <http://dx.doi.org/10.1016/j.parkreldis.2015.09.005>. 16
- ARAÚJO, L. A. d. O.; BACHION, M. M. Programa Saúde da Família: perfil de idosos assistidos por uma equipe. *Revista Brasileira de Enfermagem*, v. 57, n. 5, p. 586–590, 2004. ISSN 0034-7167. 19
- ATRRAIN. 2008. Disponível em: <https://www.atrainceu.com/>. Acesso em: 15 janeiro 2018. 12, 19, 20
- BARBOSA, E. R.; SALLEM, F. A. S. Doença de Parkinson – Diagnóstico. *Neurociências*, v. 13, p. 158–165, 2005. 20
- BEER, R. F. et al. Target-dependent differences between free and constrained arm movements in chronic hemiparesis. *Experimental Brain Research*, v. 156, n. 4, p. 458–470, 2004. ISSN 00144819. 23
- BISHOP, C. N. *Pattern recognition and machine learning*. Singapore: Springer, 2006. 16, 28, 29, 34
- BLAHUT, R. E. *Fast algorithms for digital signal processing*. [S.l.]: Addison-Wesley Publishing Company, 1985. 28
- BLASIUS, B. J.; MERRITT, R. W. Field and laboratory investigations on the effects of road salt (NaCl) on stream macroinvertebrate communities. *Environmental Pollution*, v. 120, n. 2, p. 219–231, 2002. ISSN 02697491. 21
- BRAGA, N. F. *Efeito do ritmo nos membros superiores na doença de parkinson – abordagem interdisciplinar entre terapia ocupacional e musicoterapia*. Tese (Doutorado) — UNIVERSIDADE FEDERAL DE MINAS GERAIS, 2013. 23
- GAGO, M. Manual para Pessoas com Parkinson. *APDPk - Associação Portuguesa de Doentes de Parkinson*, 2014. 11, 23
- GALHARDO, M. M. d. A. M. C.; AMARAL, A. K. d. F. J. do; VIEIRA, A. C. d. C. Caracterização Dos Distúrbios Cognitivos na doença de Parkinson. *Cefac*, v. 11, n. 2, p. 251–257, 2009. Disponível em: <http://www.scielo.br/pdf/rcefac/v11s2/a15v11s2.pdf>. 22
- GOLLAPUDI, S. *Practical Machine Learning: Tackle the real-world complexities of modern machine learning with innovative and cutting-edge techniques*. Birmingham: Packt Publishing Ltd, 2016. 16, 28
- GOODWIN, V. A. et al. The effectiveness of exercise interventions for people with Parkinson's disease: A systematic review and meta-analysis. *Movement Disorders*, v. 23, n. 5, p. 631–640, 2008. ISSN 08853185. 16
- GUESTIN, C.; FOX, E. *Machine Learning Foundations: A Case Study Approach*. 2016. Accessed Ago 2016. Disponível em: https://www.coursera.org/learn/ml-foundations/home/info/_links.html. 16

- HALLIDAY, D. M. et al. Coherence between low-frequency activation of the motor cortex and tremor in patients with essential tremor. *Lancet*, v. 355, n. 9210, p. 1149–1153, 2000. ISSN 01406736. 25
- HAND, D. J.; TILL, R. J. A simple generalisation of the area under the ROC curve for multiple class classification problems. *Machine Learning*, v. 45, p. 171–186, 2001. 33
- HASTIE, T.; TIBSHIRANI, J. F. R. *The Elements of Statistical Learning - Data Mining, Inference, and Prediction*. 2nd. ed. Stanford: Springer, 2008. 30
- HENRIK, B.; RICHARDS, J. W.; FETHEROLF, M. *Real-World Machine Learning*. Shelter Island: Manning Publications Co, 2016. 16, 28
- HOEHN, M. M.; YAHR, M. D. Parkinsonism: Onset, progression, and mortality. *Neurology*, v. 17, n. 5, p. 427–442, 1967. ISSN 0028-3878. 22, 23
- IBGE. *Instituto Brasileiro de Geografia e Estatística - CENSO 2010*. [S.l.]: IBGE, 2011. 19
- JOSHI, D.; KHAJURIA, A.; JOSHI, P. An automatic non-invasive method for Parkinson's disease classification. *Computer Methods and Programs in Biomedicine*, Elsevier Ireland Ltd, v. 145, p. 135–145, 2017. ISSN 18727565. 17, 55
- JOSHI, P. *Artificial Intelligence with Python*. Birmingham: Packt Publishing Ltd, 2017. 32
- KING, L. A.; HORAK, F. B. Delaying Mobility Disability in People With Parkinson Disease Using a Sensorimotor Agility Exercise Program. *Physical Therapy*, v. 89, n. 4, p. 384–393, 2009. ISSN 0031-9023. Disponível em: <https://academic.oup.com/ptj/article-lookup/doi/10.2522/ptj.20080214>. 16
- KREYZIG, E. *Advanced Engineering Mathematics*. 10. ed. New York: John Wiley Sons, 2011. ISBN 0470458364. 34
- LACANETTE, K. A Basic Introduction to Filters - Active, Passive, and Switched-Capacitor. *National Semiconductor: Application Note*, p. 1–22, 1991. 11, 25, 26
- LAHR, J. *Controle motor em pacientes com doença de Parkinson: terapia do espelho, foco de atenção e tarefa dupla*. 124 p. Tese (Doutorado) — UNIVERSIDADE ESTADUAL PAULISTA, 2015. Disponível em: <http://repositorio.unesp.br/handle/11449/132427>. 23
- LANA, R. et al. Percepção da qualidade de vida de indivíduos com Doença de Parkinson através do PDQ-39. *Revista Brasileira de Fisioterapia*, v. 11, n. 5, p. 397–402, 2007. ISSN 1413-3555. 21
- LINDVALL, O.; KOKAIA, Z.; MARTINEZ-SERRANO, A. Stem cell therapy for human neurodegenerative disorders – how to make it work. *Nat. Med.*, p. S42–S50, jul 2004. 25
- MALONE, K.; THRUN, S. *Intro to Machine Learning*. 2016. Accessed Sep 2016. Disponível em: https://br.udacity.com/course/intro-to-machine-learning--ud120/_links.html. 16
- MEIGAL, A. I. et al. Novel parameters of surface EMG in patients with Parkinson's disease and healthy young and old controls. *Journal of Electromyography and Kinesiology*, v. 19, n. 3, p. 206–213, 2009. ISSN 10506411. 18, 55

- MELLO, M. P. B. de; BOTELHO, A. C. G. Correlação das escalas de avaliação utilizadas na doença de Parkinson com aplicabilidade na fisioterapia. *Fisioterapia em Movimento*, v. 23, n. 1, p. 121–127, 2010. ISSN 1980-5918. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-51502010000100012&lng=pt&nrm. 16
- MIOTEC, E. B. L. *Miograph 2.0*. 2017. Disponível em: <http://www.miotec.com.br>. 12, 37, 39, 40, 41
- MOREIRA, C. et al. Doença De Parkinson : Como Diagnosticar E Tratar. *Fmc.Br*, v. 2, n. 022, p. 19–29, 2007. Disponível em: <http://www.fmc.br/revista/V2N2P19-29.pdf>. 21, 22
- NUSSBAUMER, H. J. *Fast Fourier Transform and Convolution Algorithms*. Berlin: Springer-Verlag, 1981. 28
- NUTT, J. G. Diagnosis and Initial Management of Parkinson. *New England Journal of Medicine*, v. 353, n. 10, p. 1021–1027, 2005. 22
- OPPENHEIN, A. V.; SCHAFER, R. W. *Digital Signal Processing*. New Jersey: Prentice Hall Inc., Englewood Cliffs, 1974. 26, 28
- POMPEU, J. E. et al. Feasibility, safety and outcomes of playing Kinect Adventures! for people with Parkinson’s disease: A pilot study. *Physiotherapy (United Kingdom)*, The Chartered Society of Physiotherapy, v. 100, n. 2, p. 162–168, 2014. ISSN 18731465. Disponível em: <http://dx.doi.org/10.1016/j.physio.2013.10.003>. 16, 24
- PRATI, R. C.; BATISTA, G. E. A. P. A.; MONARD, M. C. Curvas ROC para avaliação de classificadores. *Revista IEEE América Latina*, v. 6, p. 215–222, 2008. 33
- RASCHKA, S. *Python Machine Learning : unlock deeper insights into machine learning with this vital guide to cutting-edge predictive analytics*. Birmingham: Packt Publishing Ltd, 2015. 12, 16, 28, 29, 30, 31, 32, 42
- ROBICHAUD, J. A. et al. Variability of EMG patterns: A potential neurophysiological marker of Parkinson’s disease? *Clinical Neurophysiology*, International Federation of Clinical Neurophysiology, v. 120, n. 2, p. 390–397, 2009. ISSN 13882457. Disponível em: <http://dx.doi.org/10.1016/j.clinph.2008.10.015>. 18, 55
- RUONALA, V. et al. EMG signal morphology and kinematic parameters in essential tremor and Parkinson’s disease patients. *Journal of Electromyography and Kinesiology*, Elsevier Ltd, v. 24, n. 2, p. 300–306, 2014. ISSN 18735711. Disponível em: <http://dx.doi.org/10.1016/j.jelekin.2013.12.007>. 18, 55
- SCHENKMAN, M. L. et al. Spinal movement and performance of a standing reach task in participants with and without Parkinson disease. *Physical Therapy*, v. 81, n. 8, p. 1400–1411, 2001. ISSN 00319023. 22, 23
- SENIAM. 1999. Disponível em: <http://www.seniam.org>. Acesso em: 29 novembro 2017. 37, 38
- SHIH, M. C. et al. Neuroimagem Do Transportador De Dopamina Na Doença De Parkinson. *Arquivos de neuropsiquiatria*, v. 64, n. 3A, p. 628–634, 2006. ISSN 0004-282X. 20

- SILVA, F. D. da et al. Efeitos da Wiireabilitação Na Mobilidade de Tronco de Indivíduos com Doença de Parkinson: Um Estudo Piloto. *Revista Neurociencias*, v. 21, n. 7, p. 840–845, 2013. ISSN 01043579. 24
- SILVEIRA, D. N.; BRASOLOTTO, A. G. Reabilitação vocal em pacientes com doença de Parkinson: fatores interferentes. *Pró-Fono Revista de Atualização Científica*, Barueri (SP), v. 17, n. 2, p. 241–250, mai-ago 2005. 24
- SNEDDON, I. N. *Fourier Transforms*. New York: Dover Publications, 1995. 28
- SOUZA, C. F. M. et al. A doença de Parkinson e o processo de envelhecimento motor: uma revisão de literatura. *Rev Neurocienc*, v. 19, n. 4, p. 718–723, 2011. ISSN 01043579. 20, 21
- SPIEGEL, M. R. *Fourier Analysis with applications to boundary value problems*. New York: Mc Graw Hill, 1974. 28
- SUSMAGA, R. Confusion matrix visualization. *Intelligent Information Processing and Web Mining*, v. 25, p. 107–116, 2011. 32, 33
- TANNURE, M. C. et al. Perfil epidemiológico da população idosa de Belo Horizonte, Mg, Brasil. *Revista Brasileira de Enfermagem*, v. 63, n. 5, p. 817–822, 2010. ISSN 1413-6538. 19
- VISA, S. et al. Confusion matrix-based feature selection. *Proceedings of The 22nd Midwest Artificial Intelligence and Cognitive Science Conference*, v. 22, p. 120–127, 2011. 33
- VOON, V. et al. Psychiatric symptoms in patients with Parkinson disease pre - senting for deep brain stimulation surgery. *J Neurosurg*, v. 103, p. 246–251, 2005. 24
- WATTS, R. L.; KOOLE, W. C. *Movement Disorders: Neurologic Principles & Practice: Neurologic Principles and Practice*. 2nd. ed. New York: McGraw-Hill Medical, 2004. ISBN 0071374965. 16
- WE MOVE. PD WORKBOOK - The WE MOVE Clinician's guide to Parkinson's Disease: UNIFIED PD SCALE. v. 2, p. 23–30, 2006. Disponível em: http://img.medscape.com/fullsize/701/816/58977_UPDRS.pdf. Acesso em: 2 dezembro 2017. 22
- WERNECK, A. L. S. Doença de Parkinson: Etiopatogenia , Clínica e Terapêutica. *Revista Hospital Universitário Pedro Ernesto*, v. 9, p. 10–19, 2010. ISSN 1983-2567. 19
- WHARRAD, H. J.; JEFFERSON, D. Distinguishing between physiological and essential tremor using discriminant and cluster analyses of parameters derived from the frequency spectrum. *Human Movement Science*, v. 19, n. 3, p. 319–339, 2000. ISSN 01679457. 25

Anexos

ANEXO A – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO



UnB Gama
O novo endereço da Tecnologia.



Termo de Consentimento Livre e Esclarecido – TCLE

O (a) Senhor (a) está sendo convidado (a) a participar do projeto: Estudo sobre o sistema cardiorrespiratório e muscular de indivíduos acometidos pela doença de Parkinson. O objetivo desta pesquisa é: Verificar possíveis complicações cardiovasculares, respiratórias e musculares causadas pela Doença de Parkinson e analisar o impacto sobre a qualidade de vida.

O (a) senhor (a) receberá todos os esclarecimentos necessários antes e no decorrer da pesquisa e lhe asseguramos que seu nome não aparecerá sendo mantido o mais rigoroso sigilo através da omissão total de quaisquer informações que permitam identifica-lo (a).

A sua participação será através de uma avaliação, a ser realizada no dia e hora que o senhor (a) puder. Informamos que o (a) senhor (a) pode se recusar a responder qualquer questão que lhe traga constrangimento, podendo desistir de participar da pesquisa em qualquer momento sem nenhum prejuízo para o (a) senhor (a).

As etapas que o senhor (a) se submeterá são:

- 1. Ficha de Avaliação contemplando nível de estadiamento da doença (HY) (aproximadamente 05 minutos);**
- 2. Eletromiografia (aproximadamente 20 minutos);**

Essa pesquisa apresenta riscos mínimos aos seus participantes, pois não serão realizados procedimentos invasivos ou nocivos a sua saúde, de forma que os riscos são: alergia aos eletrodos. Sendo que para minimizar esses riscos os pesquisadores estarão treinados para posicionamento dos eletrodos. Se você aceitar participar, estará contribuindo para a detecção de complicações da doença de Parkinson precocemente, e uma melhor na qualidade de vida dos portadores da doença. Sua participação é voluntária, isto é, não há pagamento por sua colaboração.

Todas as despesas que você tiver relacionadas diretamente ao projeto de pesquisa (tais como, alimentação no local da pesquisa ou exames para realização da pesquisa) serão cobertas pelo pesquisador responsável.

Caso haja algum dano direto ou indireto decorrente de sua participação na pesquisa, você poderá ser indenizado, obedecendo-se as disposições legais vigentes no Brasil. Os resultados da pesquisa serão divulgados na Instituição Universidade de Brasília – UnB podendo ser publicados posteriormente. Os dados e materiais utilizados na pesquisa ficarão sobre guarda do pesquisador.

Se o (a) senhor (a) tiver qualquer dúvida em relação a pesquisa, por favor telefone para: Dra. Vera Regina, na instituição Faculdade da Ceilândia, 3377 – 0615, no período da tarde, ou através do e-mail veraregina@unb.br, podendo ligar a cobrar no telefone celular 8245-5298.

Este projeto foi aprovado pelo Comitê de Ética em Pesquisa da Faculdade de Ciências da Saúde (CEP/FS) da Universidade de Brasília. O CEP é composto por profissionais de diferentes áreas cuja função é defender os interesses dos participantes da pesquisa em sua integridade e dignidade e contribuir no desenvolvimento da pesquisa dentro de padrões éticos. As dúvidas com relação à assinatura do TCLE ou os direitos do participante da pesquisa podem ser esclarecidas pelo telefone (61) 3107-1947 ou do e-mail cepfs@unb.br ou cepfsunb@gmail.com, horário de atendimento de 10:00hs às 12:00hs e de 13:30hs às 15:30hs, de segunda a sexta-feira. O CEP/FS se localiza na Faculdade de Ciências da Saúde, Campus Universitário Darcy Ribeiro, Universidade de Brasília, Asa Norte. Este documento foi elaborado em duas vias, uma ficará com o pesquisador responsável e a outra com o sujeito da pesquisa.

Nome e Assinatura

Pesquisador Responsável

ANEXO B – CERTIFICADO DE APRESENTAÇÃO COBEC-SEB 2017

	<p>V Congresso Brasileiro de Eletromiografia e Cinesiologia X Simpósio de Engenharia Biomédica Integrando Engenharia e Clínica – Convergindo esforços para o bem estar das pessoas 23 a 26 de outubro de 2017 - Center Convention, Uberlândia, MG, Brasil www.sobec.com.br/cobecseb2017</p>	
<h1>CERTIFICADO</h1>		
<p>Certificamos que</p>		
<p>Jorge Luiz Ferreira Da Silva Junior</p>		
<p>apresentou o trabalho</p>		
<p>CLASSIFICAÇÃO DE PADRÕES DE MARCHA UTILIZANDO-SE DE DIFERENTES ALGORITMOS DE APRENDIZADO DE MÁQUINAS</p>		
<p>durante o V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica, realizado na cidade de Uberlândia, Minas Gerais, de 23 a 26 de outubro de 2017.</p>		
<p> Prof. Alcimar Barbosa Soares Presidente Comitê Organizador do COBEC-SEB 2017 Universidade Federal de Uberlândia</p>	<p> Prof. Fausto Berzin Presidente Sociedade Brasileira de Eletromiografia e Cinesiologia</p>	<p> Prof. Adriano de Oliveira Andrade Presidente X Simpósio de Engenharia Biomédica Universidade Federal de Uberlândia</p>



ANEXO C – CERTIFICADO DE PUBLICAÇÃO DE ARTIGO COBEC-SEB 2017

	<p>V Congresso Brasileiro de Eletromiografia e Cinesiologia X Simpósio de Engenharia Biomédica</p> <p>Integrando Engenharia e Clínica – Convergindo esforços para o bem estar das pessoas 23 a 26 de outubro de 2017 - Center Convention, Uberlândia, MG, Brasil www.sobec.com.br/cobecseb2017</p>	
<h2>CERTIFICADO</h2>		
<p>Certificamos que o trabalho</p>		
<p>CLASSIFICAÇÃO DE PADRÕES DE MARCHA UTILIZANDO-SE DE DIFERENTES ALGORITMOS DE APRENDIZADO DE MÁQUINAS</p>		
<p>Jorge Luiz Ferreira Da Silva Junior, Roberto Lima Aguiar, Bruna Da Silva Sousa, Ithallo Júnior Alves Guimarães, Vera Regina Fernandes Da Silva Marães e Lourdes Mattos Brasil</p>		
<p>foi apresentado durante o V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica, realizado na cidade de Uberlândia, Minas Gerais, de 23 a 26 de outubro de 2017.</p>		
<p> Prof. Alcimar Barbosa Soares Presidente Comitê Organizador do COBEC-SEB 2017 Universidade Federal de Uberlândia</p>	<p> Prof. Fausto Berzin Presidente Sociedade Brasileira de Eletromiografia e Cinesiologia</p>	<p> Prof. Adriano de Oliveira Andrade Presidente X Simpósio de Engenharia Biomédica Universidade Federal de Uberlândia</p>



ANEXO D – CERTIFICADO DE PUBLICAÇÃO DE ARTIGO COBEC-SEB 2017

	<p>V Congresso Brasileiro de Eletromiografia e Cinesilogia X Simpósio de Engenharia Biomédica</p> <p>Integrando Engenharia e Clínica – Convergindo esforços para o bem estar das pessoas 23 a 26 de outubro de 2017 - Center Convention, Uberlândia, MG, Brasil www.sobec.com.br/cobecseb2017</p>	
<h2>CERTIFICADO</h2>		
<p>Certificamos que o trabalho</p>		
<p>CLASSIFICAÇÃO DO POTENCIAL DE AÇÃO MUSCULAR ATRAVÉS DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINAS APLICADAS À SEMG</p>		
<p>Jorge Luiz Ferreira Da Silva Junior, Ithallo Junior Alves Guimarães, Roberto Aguiar Lima, Bruna Da Silva Sousa, Lourdes Mattos Brasil e Vera Regina Fernandes Da Silva Maraes</p>		
<p>foi apresentado durante o V Congresso Brasileiro de Eletromiografia e Cinesilogia e X Simpósio de Engenharia Biomédica, realizado na cidade de Uberlândia, Minas Gerais, de 23 a 26 de outubro de 2017.</p>		
 Prof. Alcimar Barbosa Soares Presidente Comitê Organizador do COBEC-SEB 2017 Universidade Federal de Uberlândia	 Prof. Fausto Berzin Presidente Sociedade Brasileira de Eletromiografia e Cinesilogia	 Prof. Adriano de Oliveira Andrade Presidente X Simpósio de Engenharia Biomédica Universidade Federal de Uberlândia



ANEXO E – MENÇÃO HONROSA DE MELHOR TRABALHO DO CONGRESSO COBEC-SEB 2017



MENÇÃO HONROSA

A Sociedade Brasileira de Eletromiografia e Cinesiologia, confere Menção Honrosa a
**Jorge L F Silva Junior, Ithallo J A Guimarães, Roberto A Lima, Bruna S Sousa, Lourdes M
 Brasil e Vera R F S Maraes**

peelo trabalho “Classificação Do Potencial De Ação Muscular Através De Técnicas De
 Aprendizagem De Máquinas Aplicadas à sEMG”, finalista do PRÊMIO JOHN BASMAJIAN -
 Melhor Trabalho do Congresso, apresentado durante o
**V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia
 Biomédica, em Uberlândia, MG, de 23 a 26 de outubro de 2017.**

Prof. Alcimar Barbosa Soares
 Presidente
 Comitê Organizador do COBEC-SEB 2017
 Universidade Federal de Uberlândia

Prof. Fausto Berzin
 Presidente
 Sociedade Brasileira de Eletromiografia e Cinesiologia

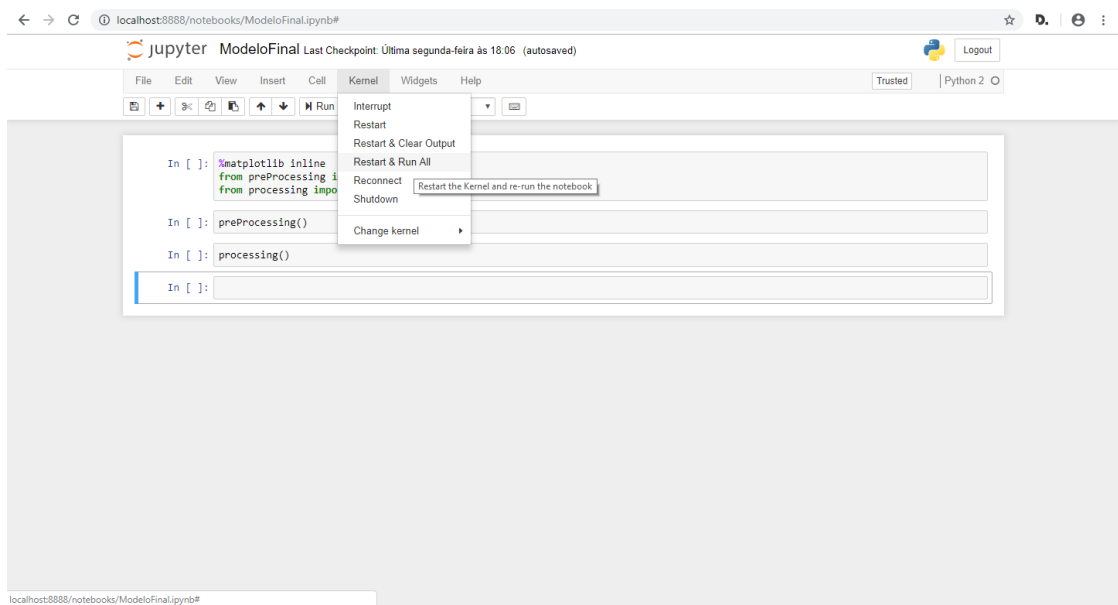
Prof. Adriano de Oliveira Andrade
 Presidente
 X Simpósio de Engenharia Biomédica
 Universidade Federal de Uberlândia

Apêndices

APÊNDICE A – INTERFACE DE OPERAÇÃO DO USUÁRIO

Interface de operação do usuário

* Para inicializar o sistema basta clicar em *Kernel > Restart & Run All*



* Após o termino do processamento, será gerado o relatório com os gráficos dos sinais e o quadro de propabilidades dos níveis:

APÊNDICE B – EXEMPLO DE CLASSIFICAÇÃO DE UMA AMOSTRA NÍVEL 3 NA ESCALA H-Y


Relatório


ModeloFinal


September 27, 2018


```
In [1]: %matplotlib inline
        from preProcessing import *
        from processing import *
```


```
In [2]: preProcessing()
```












```
In [3]: processing()
```

A probabilidade de cada nível é:



APÊNDICE C – ARTIGO COMPLETO 1 COBEC-SEB 2017

V Congresso Brasileiro de Eletromiografia e Cinesiologia | X Simpósio de Engenharia Biomédica

CLASSIFICAÇÃO DO POTENCIAL DE AÇÃO MUSCULAR ATRAVÉS DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINAS APLICADAS À sEMG

J.L.F.S Junior¹, I.J.A. Guimarães¹, R. A. Lima¹, B.S. Sousa¹, L.M. Brasil¹, V.R.F.S. Marães^{1,2}

¹Universidade de Brasília - Faculdade Gama (FGA), Brasília, Brasil

²Universidade de Brasília - Faculdade Ceilândia (FCE), Brasília, Brasil

E-mail: jorgeluizjk@gmail.com

Resumo:

A eletromiografia de superfície (sEMG) é um método não invasivo de estudo da atividade muscular. O seu mecanismo de funcionamento age a partir dos sinais enviados pelo córtex motor (neurônio motor superior/inferior) até o fuso muscular alcançando as fibras musculares periféricas, gerando a contração muscular. Essa contração terá seus sinais elétricos captados por eletrodos posicionados sobre a pele, transmitido por amplificador e transformado em sinais gráficos computadorizados, sendo que os equipamentos não apresentam um processamento de sinais que permitam a mensuração dos movimentos a partir do tipo de contração muscular. Com isso, o presente trabalho busca estabelecer um processamento de sinal permitindo prever qual o movimento realizado pelo indivíduo. As mensurações de contração muscular foram realizadas levando em consideração três arcos de movimento, sendo esses: flexão dos dedos, extensão dos dedos e flexão dos dedos apertando um corpo de prova (silicone) para obtenção de contração máxima muscular, os voluntários foram coletados três vezes a cada arco de movimento. Os dados sofreram um processamento de sinais utilizando-se da linguagem *Python*, alcançando acurácia 95,38% para predição dos movimentos de flexão dos dedos e flexão dos dedos com força máxima. Sendo assim, o processamento realizado nesse trabalho permite a longo prazo a verificação da performance muscular através dos sinais elétricos captados e analisados, permitindo que os profissionais de saúde possam fazer uso desse processamento para determinação de protocolos de tratamento.

Palavras-chave: Eletromiografia de Superfície, Processamento de sinais, Potencial de ação muscular, Aprendizagem de Máquina, Filtragem Digital.

Abstract: *Surface Electromyography (sEMG) is a noninvasive method of studying muscle activity. Its functioning mechanism acts from the signals sent by the motor cortex (upper / lower motor neuron) to the muscle spindle reaching the peripheral muscle fibers, generating muscle contraction. This contraction will have its electrical signals picked up by electrodes placed on the skin, transmitted by amplifier and transformed into computerized graphic signals, and the*

equipment does not present a signal processing that allows the measurement of the movements from the type of muscular contraction. In that way, the present work seeks to establish a signal processing which allows predicting the movement performed by the individual. Measurements of muscle contraction were performed taking into account three movement arches, such as: flexion of the fingers, extension of the fingers and flexion of the fingers while tightening a test piece (silicone) to obtain maximum muscle contraction, volunteers were collected three times for each arc of movement. The data were processed through the Python language and it reached 95.38% accuracy for prediction of flexion movements of the fingers and flexion of the fingers with maximum force. Thus, the processing performed in this work allows in the long term the verification of the muscular performance through the electrical signals captured and analyzed, allowing health professionals to make use of this processing to determine treatment protocols.

Keywords: *Surface Electromyography, Signal Processing, Muscle Action Potential, Machine Learning, Digital Filtering.*

Introdução

O Aprendizado de Máquinas (AM) tem recebido grande atenção nos últimos anos devido ao aumento da capacidade computacional tornando mais barato e robusto o processamento de algoritmos em uma grande massa de dados [1, 2]. Como um subcampo da inteligência artificial, o AM compõe um conjunto de algoritmos de autoaprendizagem capaz de adquirir conhecimento a partir de um banco de dados para realizar tomadas de decisões e fazer previsões [3]. Métodos de AM têm sido amplamente utilizados para a avaliação da marcha humana através da estimativa de parâmetros espaço-temporais [4].

O Potencial de ação muscular ocorre através da interação entre o córtex motor e o fuso muscular. O potencial de ação é iniciado no motoneurônio alcançando as fibras de terminação nervosa, que ao liberar as entradas de sódio nos canais de ação inicia-se o potencial na fibra muscular [5].

O potencial de ação da fibra muscular permite a liberação de íons de cálcio no retículo sarcoplasmático promovendo a ligação da actina miosina, esses eventos

fisiológicos são extremamente importantes para a realização dos movimentos [5].

A eletromiografia verifica a condução elétrica dos potenciais de ação, mensurando o grau de contração e força muscular de forma precisa expressa em frequência. De forma que os profissionais de saúde ao obterem esses dados de potencial de ação podem realizar modificações nos protocolos de tratamento para melhorar a performance muscular, alcançando os objetivos para diferentes patologias, principalmente doenças neurodegenerativas e ortopédicas que afetam diretamente o potencial de ação muscular [6].

Essa ferramenta clínica permite ainda a determinação do nível de tratamento na área desportiva, pois o potencial de ação muscular sofre modificações durante a produção de lactato em esportes de médio e alto rendimento, dessa forma a elevação das frequências de contração podem ser tidas como parâmetros de tratamento para melhora do desempenho dos atletas [6].

Com isso, o presente trabalho busca estabelecer um processamento de sinal permitindo prever qual o movimento realizado pelo indivíduo.

Materiais e métodos

Esta pesquisa foi aprovada pelo Comitê de Ética e Pesquisa da Faculdade da Saúde da Universidade de Brasília CAAE (38386714.8.0000.0030). A pesquisa foi dividida em duas etapas, a primeira etapa foi a coleta de dados, foram selecionados 10 voluntários, 6 indivíduos do sexo masculino e 4 do sexo feminino, sendo orientados a realizar três movimentos: flexão dos dedos, extensão dos dedos e flexão dos dedos com grau de força máxima. Foi solicitado que cada voluntário realizasse cada movimento por 3,5 segundos. O grupo muscular escolhido para a captação do sinal EMG foi o flexor superficial dos dedos direito. Os sinais de EMG de superfície foram coletados por meio de um protótipo de eletromiógrafo, que está em fase de construção e, possui até o presente momento apenas um canal (sendo 3 eletrodos: um aterramento e dois eletrodos diferenciais). Esse sistema fez o uso de um *Arduino Nano* para realizar a conversão dos sinais analógicos para o domínio digital e contou com uma resolução de 10 bits, 1024 valores diferentes, alocados entre 0 e 1,1 volts (aproximadamente 1 mV de resolução). O sinal foi coletado com uma taxa real de 1904 amostras por segundo. Para uma melhor captação dos sinais eletromiográficos foram realizados os procedimentos de tricotomia, limpeza da oleosidade e resíduos biológicos da pele, preconizados pelo SENIAM [7]. Na Figura 1 podemos observar o sinal sEMG dos três eventos realizados.

A segunda etapa foi o processamento de sinais, realizado através da implementação de filtros digitais e técnicas de Aprendizado de Máquina. Para o processamento dos sinais foram utilizadas a linguagem de programação *Python* e bibliotecas como: *NumPy*, *SciPy*, *sklearn.ensemble* e *sklearn.metrics* [9,10].

Após a coleta dos sinais houve uma etapa de pré-processamento, onde foram aplicados dois filtros digitais.

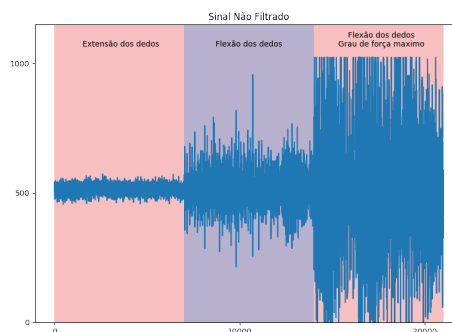


Figura 1 – Sinal sEMG não filtrado dos 3 eventos realizados

Passa-faixa de 20-450 Hz: com o objetivo de limitar os sinais de estudo à faixa de frequência dos músculos (20-500 Hz) [10].

Passa-baixa de 180 Hz: este filtro foi utilizado a fim de obter-se uma melhor diferenciação entre os padrões dos movimentos realizados. A Figura 2 mostra a combinação dos dois filtros aplicada ao sinal original.




Figura 2 – Sinal sEMG filtrado

Em seguida, foi criada uma série temporal a partir do sinal filtrado. De modo que uma janela, com tamanho de 500 amostras, percorreu todo o sinal, gerando novas características de entrada para alimentar o algoritmo de AM. Para a escolha do algoritmo a ser implementado foi realizado um estudo sobre qual o algoritmo de AM que houvesse a melhor performance para classificar este tipo de dado. Deste modo, o algoritmo Random Forest Classifier (RFC) foi escolhido. O RFC é um classificador de ótimo desempenho, escalabilidade e fácil utilização. Considerado como um conjunto de árvores de decisões,

seu conceito é combinar classificadores básicos muito simples para construir um modelo mais robusto, por sua vez, ter uma melhor generalização de erros, sendo menos suscetível a *overfitting* [3, 11].

Por fim, para avaliar a performance do classificador foram utilizadas as métricas sensibilidade, especificidade, acurácia e precisão baseadas na matriz confusão [12, 13, 14].

Resultados

A respeito da avaliação de performance do classificador, esta disposto na Figura 3 a matriz confusão normalizada. Na Tabela 1 encontra-se o resultado da análise realizada sobre a matriz confusão.

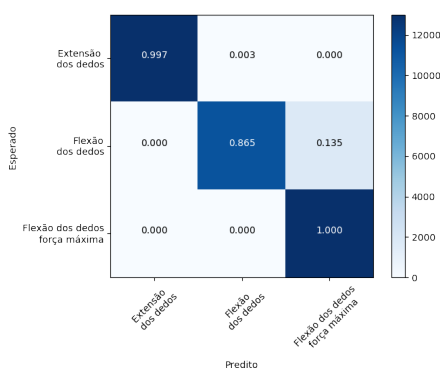


Figura 3 – Matriz Confusão não normalizada

Tabela1 – Análise da Matriz Confusão

	Extensão dos dedos	Flexão dos dedos	Flexão dos dedos – força máxima
Sensibilidade	99,31%	86,49%	99,98%
Especificidad	100,00%	99,83%	93,25%
e			
Precisão	100,00%	99,58%	88,10%
Acurácia total		95,38%	

O método de processamento de sinais empregado apresentou alta acurácia nos diferentes arcos de movimento, e também ótimos percentuais de especificidade, sensibilidade e precisão. O que garante um grande nível de confiança na predição dos movimentos realizados. O método permite também a visualização dos movimentos através da análise dos dados eletromiográficos, demonstrando os respectivos potenciais de ação das musculaturas utilizadas.

Discussão

O processamento de sinais realizado nos dados permite ao analisador a verificação dos diferentes potenciais de ação muscular de cada voluntário, dessa forma o profissional de saúde consegue avaliar o grau de força muscular de cada indivíduo, em diferentes contrações musculares, seja ela concêntrica, excêntrica ou isométrica com sustentação da força.

A respeito da correlação da força muscular ao potencial de ação, o estudo de LOSS [15] realizou uma correlação da força muscular e a eletromiografia a partir das análises significativas de correlação de musculatura mastigatória, verificando durante contração isométrica, ou seja, sustentação da posição sem movimentação dinâmica, o grau de força muscular, sendo uma limitação para os autores os movimentos concêntricos/dinamismo. O presente estudo estabelece um processamento de sinal capaz de analisar o potencial muscular independentemente do tipo de contração realizado, avançando nas técnicas apresentadas em alguns estudos que correlacionam a força muscular aos dados eletromiográficos em posições isométricas.

Outro aspecto analisado foi a capacidade de diagnóstico ou determinação de protocolos de tratamento através do potencial de ação. Estudos como o de Garcia et al; 2004 [16] e Bandeira et al; 2009 [17] realizaram eletromiografia em voluntários para diagnósticos de determinadas condições em saúde. O estudo [16] verificou durante o incremento de carga o momento de fadiga muscular de atletas, tendo a fadiga como parâmetro para o número de repetições e carga máxima alcançada.

Enquanto o artigo [17] utilizou a eletromiografia para mensurar a perda de força muscular durante isquemia induzida, sendo observado que quanto menor o valor das frequências do EMG, os movimentos aconteciam em menores amplitudes durante a extensão de punho, de forma que esse tipo de diagnóstico realizado precocemente permite que o profissional de saúde possa prevenir a perda total dos movimentos, ou estabelecer uma recuperação mais rápida do paciente.

Nos artigos mencionados acima, as correlações entre o potencial muscular e o grau de força foram realizados de forma associativa e por análise estatística, sem processamento dos sinais, com isso o presente estudo permite uma avaliação de força, performance e diagnóstico tenha uma melhor acurácia, precisão e sensibilidade para análise da potencia muscular a partir de dados eletromiográficos.

Conclusão

O processamento de sinais realizado nesse estudo demonstrou que a eletromiografia pode ser uma ferramenta de avaliação e diagnóstico a partir da correlação entre o potencial muscular e o grau de força muscular.

Esse processamento pode ser útil principalmente nas áreas desportiva, neurológica e ortopédica. Tendo em vista que as análises realizadas podem ser em diferentes tipos de contração, permitindo assim que o profissional

de saúde verifique precocemente a perda ou ganho de força e o momento de fadiga muscular durante a avaliação e tratamento.

Agradecimentos

Agradecemos a colaboração dos voluntários, ao Programa de Pós-Graduação em Engenharia Biomédica (PPGEB) de Brasília, a Coordenação de aperfeiçoamento de pessoal de nível superior (CAPES) e também a Fundação de Apoio à Pesquisa do Distrito Federal (FAPDF) pelo auxílio financeiro.

Referências

- [1] Guestrin, C., Fox, E.: Machine Learning Foundations: A Case Study Approach. Coursera. Accessed Ago 2016. <https://www.coursera.org/learn/ml-foundations/home/info-links.html>
- [2] Malone, K., Thrun, S.: Intro to Machine Learning. Udacity. Accessed Sep 2016. <https://br.udacity.com/course/intro-to-machine-learning/ud120/links.html>
- [3] Raschka, S.: Python Machine Learning : Unlock Deeper Insights Into Machine Learning with this Vital Guide to Cutting-edge Predictive Analytics. Packt Publishing Ltd, Birmingham (2015)
- [4] Mannini, A., Trojaniello, D., Sabatini, A.C.A.M.: A machine learning framework for gait classification using inertial sensors: application to elderly, post-stroke and huntington's disease patients. *sensors* (2016)
- [5] GUYTON, A.C.; HALL, J.E. Tratado de Fisiologia Médica. 11ª ed. Rio de Janeiro, Elsevier Ed., 2006.
- [6] Santos MCA, Semeghini TA, Azevedo FM, Colugnati DB, Negrão FRF, Alves N et al . Análise da fadiga muscular localizada em atletas e sedentários através de parâmetros de frequência do sinal eletromiográfico. *Rev Bras Med Esporte* [Internet]. 2008 Dec [cited 2017 July 30]; 14(6): 509-512.
- [7] Hermens JH, Freriks B, Klug CD, Rau G. Development of recommendations for SEMG sensors and sensor placement procedures. *J Electromyogr Kinesiol.* 2000; 14:361-74.
- [8] Hakonen M, Piitulainen H, Visala A. Current state of digital signal processing in myoelectric interfaces and related applications. *Biomedical Signal Processing and Control.* 2015;18(1):334-59.
- [9] WALT, S. V. D.; COLBERT, S. C.; VAROQUAUX, G. The NumPy Array: A Structure for Efficient Numerical Computation, *Computing in Science & Engineering*, 13, 22-30 (2011), DOI:10.1109/MCSE.2011.37
- [10] PEDREGOSA, F.; et al.. Scikit-learn: Machine Learning in Python. *JMLR* 12, pp. 2825-2830, 2011.
- [11] Hastie, T., Tibshirani, J.F.: The Elements of Statistical Learning - Data Mining, Inference, and Prediction, 2nd edn. Springer, Stanford (2008)
- [12] Susmaga, R.: Confusion matrix visualization. *Intelligent Information Processing and Web Mining* 25, 107-116 (2011)
- [13] Visa, S., Ramsay, B., Ralescu, A., Knaap, E.: Confusion matrix-based feature selection. *Proceedings of The22nd Midwest Artificial Intelligence and Cognitive Science Conference*, 120{127 (2011)
- [14] Begg, R., Kamruzzaman, J.: A machine learning approach for automated recognition of movement patterns using basic, kinetic and kinematic gait data. *Journal of Biomechanics* 38, 401{408 (2005)
- [15] LOSS, Jefferson et al. Sugestão de método para correlacionar força muscular e eletromiografia. **Movimento (ESEFID/UFRGS)**, Porto Alegre, v. 4, n. 8, p. 33-40, set. 2007. ISSN 1982-8918.
- [16] Garcia MAC, Magalhães J, Imbiriba LA. Comportamento temporal da velocidade de condução de potenciais de ação de unidades motoras sob condições de fadiga muscular. *Rev Bras Med Esporte* [Internet]. 2004 Aug [cited 2017 July 30]; 10(4): 299-303
- [17] Bandeira CCA, Berni KCS, Rodrigues-Bigaton D. Análise eletromiográfica e força do grupo muscular extensor do punho durante isquemia induzida. *Rev. bras. fisioter.* [Internet]. 2009 Feb [cited 2017 July 30]; 13(1): 31-37

APÊNDICE D – ARTIGO COMPLETO 2 COBEC-SEB 2017

V Congresso Brasileiro de Eletromiografia e Cinesiologia | X Simpósio de Engenharia Biomédica

Classificação de padrões de marcha utilizando-se de diferentes algoritmos de aprendizado de máquinas

J.L.F.S Junior¹, R.A. Lima¹, B.S. Sousa¹, I.J.A. Guimarães¹, V.R.F.S. Marães^{1,2}, L.M. Brasil¹

¹Universidade de Brasília - Faculdade Gama (FGA), Brasília, Brasil

²Universidade de Brasília - Faculdade Ceilândia (FCE), Brasília, Brasil

E-mail: jorgeluizjk@gmail.com

Resumo:

O desenvolvimento de tecnologias em saúde apresenta um grande impacto na qualidade de vida dos indivíduos, sendo estudado cada vez mais o aprendizado de máquinas com principal objetivo de automatizar procedimentos em saúde e apresentar soluções para avaliações subjetivas. Tendo em vista que uma das formas de diagnóstico de patologias ocorre através da análise da marcha, esse artigo busca analisar as fases da marcha de forma precisa através do aprendizado de máquinas. Para a análise da marcha foi utilizado o aparelho *Qualisys Track Manager* (QTM), em que foram posicionados eletrodos nas principais tuberosidades ósseas envolvidas no movimento de marcha, sendo solicitado ao voluntário a realização de cinco vezes os movimentos de marcha em espaço determinado durante cinco segundos. Foram utilizados os dados de maior impacto na qualidade da análise da marcha sendo estes as angulações do joelho durante as fases da marcha proporcionando maior precisão, com análise comparativa de sete diferentes técnicas de classificação. Os resultados analisados demonstram que o uso de diferentes algoritmos para a classificação da marcha pode ser determinante na identificação dos padrões de marcha, de forma que o algoritmo Random Forest apresentou 99,50% de acurácia. Dessa forma, o presente estudo apresenta uma maneira de análise e classificação da marcha, representando uma forma automatizada da análise cinemática da marcha, podendo futuramente auxiliar no diagnóstico de patologias e prescrição de dispositivos auxiliares na marcha.

Palavras-chave: Classificação, Aprendizado de Máquinas, Marcha.

Abstract: The development of health technologies has a great impact on the quality of life of individuals, being increasingly studied the learning of machines with the main objective of automating health procedures and presenting solutions for subjective evaluations. Considering that one of the ways of diagnosing pathologies occurs through gait analysis, this article seeks to analyze gait phases accurately through machine learning. For the gait analysis, the *Qualisys Track Manager* (QTM) was used, in which electrodes were positioned in the main bone tuberosities involved in the walking movement, and the volunteer was asked to perform five times the walking movements in a

determined space for five seconds. The data of greater impact in the quality of the gait analysis were used, providing greater precision, with a comparative analysis of seven different classification techniques. The results show that the use of different algorithms for gait classification can be determinant in the identification of gait patterns, so that the Random Forest algorithm presented 99.50% accuracy. Thus, the present study presents a way of analysis and classification of gait, representing a form automation of the kinematic gait analysis, and may in the future help in the diagnosis of pathologies and prescription of auxiliary devices in gait.

Keywords: Classification, Machine Learning, March.

Introdução

A inteligência artificial apresenta diversos subcampos, sendo que um dos mais pesquisados e estudados atualmente é a respeito do Aprendizado de Máquinas (AM) ^[1]. O AM pode ser utilizado para resolução de diversos problemas em saúde, sendo muito explorado no campo da Engenharia Biomédica ^[1,2].

A análise cinemática da marcha apresenta-se como uma forma de diagnóstico de patologias, prescrição de tratamento fisioterapêutico, orientações ergonômicas e confecção de órteses e próteses para cada indivíduo ^[3,4]. Dentre as doenças neuromusculares e ortopédicas que podem causar anormalidades ou uma marcha patológica, têm-se: Acidente Vascular Encefálico, Doença de Huntington, Osteoartrite, Doenças Cerebelares, Parkinson, Esclerose Lateral Amiotrófica, e também em indivíduos que sofreram amputação como transfemorais (acima da articulação do joelho) e transtibiais (na altura da tibia), dentre outras ^[3,4].

Atualmente a análise da marcha em laboratórios são realizadas pelos profissionais de saúde demandando tempo, prática e repetidas avaliações para resultados mais precisos, através do aprendizado de máquinas esse processo pode ser realizado de forma rápida, automatizada e precisa, permitindo que o profissional de saúde tenha um diagnóstico precoce.

Com isso, o presente artigo busca analisar as fases da marcha de forma precisa através do aprendizado de máquinas.

Materiais e métodos

Para a análise da marcha foi utilizado o aparelho *Qualisys Track Manager* (QTM) do laboratório de análise de marcha humana na Universidade de Brasília – Campus Ceilândia, em que foram posicionados eletrodos nas principais tuberosidades ósseas envolvidas no movimento de marcha, sendo estes: crista ilíaca, trocante maior, patela, malelo lateral e hálux. Para o presente estudo foi selecionado um paciente analisado previamente por dois fisioterapeutas, não apresentando alterações patológicas na marcha, mas sim alterações posturais durante o movimento. Foi solicitado ao voluntário a realização de cinco vezes os movimentos de marcha em espaço de aproximadamente dois metros, com duração média de cinco segundos de deslocamento.

Após o processamento da análise do QTM, os dados foram exportados em formato .mat do MATLAB®, e analisados através dos algoritmos do software Python™ 2.7.12. Foram utilizados os dados de maior impacto na qualidade da análise da marcha proporcionando maior precisão sendo estes: as angulações do joelho durante as fases da marcha, com análise comparativa de sete diferentes técnicas de classificação, sendo estas: Ada Boost, Decision Tree, Gaussian Naive Bayes, K-Nearest Neighbors SVM – RBF Kenel, SVM – Polynomial Kernel, Random Forest. Para a análise estatística dos dados foram realizados a matriz de confusão, realizada pelo software Python™ 2.7.12.




Figura 1. Posicionamento dos eletrodos, Imagem própria, (n=1), 2016.

Resultados

Classifiers	Classes	Performance measures			
		Sensitivity	Precision	Specificity	Accuracy
SVM - RBF Kenel	Normal	98.85 %	98.80 %	99.34 %	99.02 %
	Stair Ascend	100.00 %	98.41 %	99.19 %	
	Stair Descend	98.68 %	100.00 %	100.00 %	
SVM - Polynomial Kernel	Normal	100.00 %	98.53 %	99.25 %	99.00 %
	Stair Ascend	97.01 %	100.00 %	100.00 %	
	Stair Descend	100.00 %	98.53 %	99.25 %	
Gaussian Naive Bayes	Normal	93.55 %	85.21 %	91.88 %	96.96 %
	Stair Ascend	68.66 %	95.51 %	96.83 %	
	Stair Descend	98.68 %	83.40 %	90.18 %	
Random Forest	Normal	100.00 %	98.53 %	99.25 %	99.50 %
	Stair Ascend	98.51 %	100.00 %	100.00 %	
	Stair Descend	100.00 %	100.00 %	100.00 %	
Decision Tree	Normal	96.83 %	98.68 %	99.34 %	95.22 %
	Stair Ascend	92.54 %	94.33 %	99.18 %	
	Stair Descend	94.74 %	92.70 %	96.27 %	
Ada Boost	Normal	74.29 %	83.63 %	91.79 %	82.78 %
	Stair Ascend	77.61 %	73.72 %	91.44 %	
	Stair Descend	86.84 %	91.97 %	96.21 %	
K-Nearest Neighbors	Normal	96.83 %	100.00 %	100.00 %	99.02 %
	Stair Ascend	100.00 %	97.15 %	99.19 %	
	Stair Descend	98.68 %	100.00 %	100.00 %	

Os resultados obtidos pela análise dos classificadores dos eventos de marcha, estão apresentados na Tabela 1.

Tabela 1 – Classificadores dos eventos da marcha.

Discussão

Para o desenvolvimento desse artigo, foi utilizado como base os artigos “Cerebellar Model Articulation Control artificial Neural Network (CMAC ANN)”^[5] e “Multilayer Perceptron Artificial Neural Network (MLP)”^[6], tendo em vista que o objetivo dos artigos eram baseados na prescrição de próteses e criação de um controle autônomo na soquete, o presente estudo verificou os aspectos importantes na marcha que afetam também as amputações de membros inferiores, principalmente transfemorais (abaixo da articulação do joelho) e transtibiais (na altura da tibia).

Após um aprofundamento na análise da marcha, foi observado que as relações angulares obtidas através do QTM seria possível determinar com classificadores as possíveis alterações angulares e estruturais que afetam a cinemática e biomecânica da marcha, tanto em amputações quanto em doenças neuromusculares e ortopédicas.

No processo de análise das características biomecânicas, observa-se que a metodologia de análise e qualidade do sinal pode impactar na classificação, de forma que quanto maior o número de ciclos da marcha analisados, melhor seria a precisão de diagnóstico. Uma análise gráfica nas imagens de simulação^[7,8] dos diferentes padrões de marcha propostos chamou a atenção dos autores para dois pontos que diferiram bastante, sendo baseado a análise das fases levando em consideração o detalhamento da Figura 2^[9].




Figura 2. Fases da marcha com detalhamento, Barela AMF, 2005.

Os ângulos dos joelhos e as distancias dos pés em relação ao tronco foram bem distintos entre as marchas. Com isso, definiu-se quatro características (po_foot_r, pos_foot_l, vz_r, vz_l) que foram responsáveis pelo maior ganho de acurácia do classificador^[7,8].

Conclusão

O presente estudo analisou e classificou diferentes padrões de marcha de acordo com as diversas realizações do movimento, demonstrando que o

aprendizado de máquinas apresenta eficácia em suas técnicas, podendo ser utilizada nos campos de inteligência artificial, sistemas inteligentes e engenharia biomédica.

De forma que os resultados apresentados representam uma forma de automatização da análise cinemática da marcha tendo em vista que o mesmo indivíduo realizou diversas formas de marcha, como simulação de subida e descida de escadas, marcha com extensão de joelho, sendo que o avaliador não teve acesso as filmagens e apenas com o aprendizado de máquinas conseguiu determinar o que estava ocorrendo na marcha, podendo futuramente auxiliar no diagnóstico de patologias e prescrição de dispositivos auxiliares na marcha, sendo observado que os ângulos do tornozelo, quadril e joelho são de extrema importância para a identificação de patologias pelo algoritmo.

Sendo necessário a execução do presente estudo em diferentes marchas patológicas para posteriormente ser implementado no sistema único de saúde.

Agradecimentos

Agradecemos a colaboração do voluntário, ao Programa de Pós-Graduação em Engenharia Biomédica (PPGEB) de Brasília, e a Coordenação de aperfeiçoamento de pessoal de nível superior (CAPES) pelo auxílio financeiro.

Referências

- [1] Guestrin, C., Fox, E.: Machine Learning Foundations: A Case Study Approach. Coursera. Accessed Ago 2016.
<https://www.coursera.org/learn/mlfoundations/home/info/links.html>
- [2] Malone, K., Thrun, S.: Intro to Machine Learning. Udacity. Accessed Sep 2016.
<https://br.udacity.com/course/intro-to-machine-learning/ud120/links.html>
- [3] Raschka, S.: Python Machine Learning : Unlock Deeper Insights Into Machine Learning with this Vital Guide to Cutting-edge Predictive Analytics. Packt Publishing Ltd, Birmingham (2015)
- [4] Mannini, A., Trojaniello, D., Sabatini, A.C.A.M.: A machine learning framework for gait classification using inertial sensors: application to elderly, post-stroke and huntington's disease patients. sensors (2016)
- [5] Lima, R.A., Marães, V.R.F.S., Martins, J.P., Brasil, L.M.: Knee simulation using cmac ann. In: Ja_ray, D.A. (ed.) World Congress on Medical Physics and Biomedical Engineering, June 7-12, 2015, Toronto, pp.1159-1162 (2015). IFMBE Proceedings
- [6] Guimarães, I.J.A., Lima, R.A., Marães, V.R.F.S., Brasil, L.M.: Human knee simulation using multilayer perceptron artificial neural network. In: XXV Congresso Brasileiro de Engenharia Biomédica (2016).
- [7] Perry, J., Burn_eld, J.M.: Gait Analysis: Normal and Pathological Function, 2nd edn. SLACK Incorporated, Thorofare (2010).
- [8] Abbas, S.J., Abdulhassan, Z.M.: Kinematic analysis of human climbing up and down stairs at different inclinations. Eng. & Tech. Journal 31, (2013).
- [9] Barela AMF, Stolf SF, Duarte M. Biomechanical characteristics of adults walking in shallow water and land. Journal of Electromyography and Kinesiology. 2005; 16:250-6.

APÊNDICE E – ARTIGO COMPLETO 3 COBEC-SEB 2017

Anais do V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica - ISBN: 978-85-5722-065-2 - DOI: 10.29327/cobecseb.78924

DESAFIOS NA CAPTAÇÃO DO SINAL DE ELETROMIOGRÁFICO DO MÚSCULO DIAFRAGMA

L.R.S.M. Kawamura*, B.S. Silva*, J.F.L.S. Júnior*, V.R.F. Marães**

*Mestranda em Engenharia Biomédica, Universidade de Brasília, Distrito Federal, Brasil

**Docente do colegiado de Fisioterapia e Pós Graduação em Engenharia Biomédica, Universidade de Brasília, Distrito Federal, Brasil

e-mail: lorena.kawamura@gmail.com

Resumo: Nos últimos anos, o interesse na análise de sinais de eletromiografia dos músculos respiratórios tem aumentado devido ao número de doenças neuromusculares e respiratórias que impactam na força diafragmática e sobrecarregam os músculos acessórios. Porém o registro adequado da excursão diafragmática é um grande desafio. O presente artigo busca e apresentar os desafios a respeito da viabilidade do uso da eletromiografia (EMG) de superfície para análise da atividade elétrica muscular do diafragma. Com esse propósito foram procurados na literatura artigos com possíveis padronizações de posicionamento de eletrodos, e realizado as mensurações de cinco pacientes sendo três idosos portadores da doença de Parkinson e dois jovens saudáveis. O aparelho utilizado foi o Miotool (Empresa Miotec®, eletrodos em formato Jacaré). Observou-se que a falta de um consenso a cerca do opcionalmente dos eletrodos de superfície dificulta uma metodologia eficaz para que se obtenha a captação do sinal eletromiográfico do músculo diafragma. Sendo assim, sugere-se a criação de um protocolo para posicionamento da musculatura diafragmática para melhor captação e análise dos sinais.

Palavras-chave: diafragma, eletromiografia, eletrodo.

Abstract: In recent years, interest in the analysis of respiratory muscle electromyography signals has increased due to the number of neurological and respiratory diseases that impact the diaphragmatic excursion and overload the accessory muscles. However, the proper diaphragmatic excursion record is a major challenge. This paper aims to present the challenges regarding the feasibility of the use of surface electromyography (EMG) to analyze the muscular electrical activity of the diaphragm. With this purpose, we have searched in the literature for articles with possible electrode positioning standardization, developed with measurements of five

patients, three elderly patients with Parkinson's disease and two healthy youngsters. The used device was Miotool (Miotec® Company, alligator clip electrodes). It was observed that the lack of a consensus about the surface electrodes positioning hinders an effective methodology to obtain the capture of the diaphragm muscle electromyographic signal. Therefore, we suggest the creation of a protocol for the diaphragmatic muscles positioning to a better capture and analyzation of the signals.

Keywords: diaphragm, electromyographic, electrode.

Introdução

A eletromiografia (EMGs) de superfície é um método de registro da atividade elétrica muscular. A aquisição desse registro se dá por meio do posicionamento de eletrodos sobre a pele [1]. Por se tratar de um método não invasivo e indolor sua aplicação pode ser feita sempre que necessária [2]. Alguns autores usaram a técnica de eletromiografia de superfície tentando obter êxito nos estudos de músculos profundos posicionando os eletrodos em regiões específicas onde músculos profundos apresentam uma porção superficial [3].

O diafragma é um músculo único e transversal, separa a caixa torácica do abdômen, e possui duas partes, uma parte muscular e a periférica (tendinosa). O músculo se origina na coluna e costelas e tem sua inserção no centro tendinoso da aponeurose central. A porção muscular do diafragma se subdivide em: porção vertebral, porção esternal e porção costal. A porção costal é toda a porção lateral, sua origem é na parte externa das costelas. [4]

A musculatura ventilatória é acometida em doenças neuromusculares e respiratórias [5]. O baixo recrutamento muscular do diafragma propicia a morbidez. Quando há uma restrição mecânica

diafragmática, há o comprometimento do equilíbrio ventilação/perfusão o que resulta em hipoventilação [6].

O diafragma é o principal músculo da respiração e várias doenças tem impacto direto sobre seu desempenho. Estudos que analisem a excursão diafragmática são escassos na literatura devido a dificuldade em se avaliar o músculo por causa de seu posicionamento anatômico. Dessa forma o objetivo desse estudo é apresentar os desafios a respeito da viabilidade do uso da eletromiografia (EMG) de superfície para análise da atividade elétrica muscular do diafragma.

Materiais e métodos

Esta pesquisa foi aprovada pelo Comitê de Ética e Pesquisa da Faculdade da Saúde da Universidade de Brasília CAAE (66951316.0.0000.0030), fazendo parte de um projeto maior financiado pelo Programa de Pós Graduação em Engenharia Biomédica – UnB. A pesquisa foi dividida em duas etapas: pesquisa de padronização de posicionamento na literatura e a segunda a realização da captação de sinais eletromiográficos em indivíduos com Parkinson e saudáveis.

Na primeira etapa foi realizado a busca em bases de dados eletrônicas: PubMed, SciELO, Lilacs, BVS, Dedalus e BCE, com uso de palavras chave: eletromiografia, posicionamento, diafragma. Na segunda etapa, foram realizadas análises sobre a dificuldade na captação de sinais eletromiográficos, sendo recrutados para o estudo dois jovens (20 e 24 anos) e três idosos (56, 64 e 68 anos) portadores da doença de Parkinson, tendo em vista que os critérios de inclusão eram indivíduos jovens sadios entre 18 e 25 anos e portadores da doença de Parkinson entre 18 e 70 anos, objetivando comparar entre indivíduos jovens saudáveis e idosos com uma patologia que afeta o músculo diafragma as dificuldades no posicionamento dos eletrodos e na captação de sinal, sendo excluídos idosos que não fossem portadores da doença de Parkinson, jovens com quaisquer patologia. Para a captação do sinal eletromiográfico do diafragma foi usado o aparelho o Miotool (Empresa Miotec®, eletrodos em formato Jacaré). Os pacientes foram orientados a respeito do procedimento de colocação dos eletrodos e manutenção da respiração basal, foi realizado a tricotomia, antissepsia e colocação dos eletrodos em pontos estratégicos baseando-se na literatura.

Os eletrodos eram não invasivos com formato duplo (Miotec®) e o eletrodo referência (Kendall®) com polo único. O local de aplicação dos eletrodos foram no músculo esternocleidomastóideo direito e esquerdo, diafragma direito e esquerdo, reto do abdômen do lado direito e esquerdo. A colocação no eletrodo no

diafragma direito foi entre o sexto espaço intercostal. A colocação do eletrodo no diafragma esquerdo foi no sétimo espaço intercostal na linha hemiclavicular [7], tendo em vista que durante três coletas de dados de cada indivíduo os melhores resultados foram no sexto espaço e sétimo. Tentamos manter a simetria, mas devido à área cardíaca, quando o eletrodo é colocado no diafragma esquerdo no sexto espaço intercostal os batimentos cardíacos do paciente interferem. A equipe considerou o conhecimento anatômico e fisiológico juntamente com estudo que demonstrou bons resultados [7], para adotar uma padronização a cerca do posicionamento dos eletrodos no sexto e sétimo espaço intercostal em nosso estudo. O eletrodo referência foi colocado na crista ilíaca esquerda. A coleta dos sinais foi realizada uma única vez em cada indivíduo.

Resultados

Na primeira etapa do estudo foram incluídos 24 artigos, sendo observado que os posicionamentos dos artigos apresentam diferentes pontos como referência para a musculatura do diafragma, sendo que 17 artigos (71%) apresentaram como o 6 e 7º e 8º espaço intercostal direito e esquerdo respectivamente, como pontos de captação e apenas 7 (29%) como o 8º e 9º espaço intercostal direito e esquerdo, respectivamente. Em relação a padronização da musculatura acessória respiratória, foram utilizados a padronização do Surface Electromyography for the Non-Invasive Assessment of Muscles (SENIAM).

No grupo dos idosos os eletrodos se mostraram de difícil retirada, ocasionado pela textura da pele do idoso sendo mais fina em comparação aos indivíduos adultos saudáveis, causando desconforto durante a retirada.

A gordura subcutânea se demonstrou determinante na captura de sinais, independentemente da idade do sujeito avaliado. Um dos sujeitos jovens apresentava quadro de sedentarismo, apresentando gordura subcutânea abdominal e torácica maior, dificultando a captação do sinal elétrico muscular, não ocorrendo nos demais voluntários ativos fisicamente, que apresentavam pouca gordura subcutânea.

Outro fator limitador, são as góticulas de suor, pois impedem a aderência do eletrodo na pele, sendo que um dos idosos da nossa amostra transpirou após a colocação dos eletrodos, sendo observado uma perda do posicionamento do eletrodo, interrompendo imediatamente a captação dos sinais elétricos da musculatura da excursão diafragmática.

Os idosos do estudo eram portadores da doença de Parkinson. A alteração postural na doença de Parkinson é um sintoma frequente. Na doença de Parkinson é comum a camptocormia e a síndrome de Pisa [8]. Alterações posturais dificultam a colocação e fixação dos eletrodos na pele.

Anais do V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica - ISBN: 978-85-5722-065-2 - DOI: 10.29327/cobecseb.78924

Para a captação de musculatura acessória da respiração, como os músculos esternocleidomastoideo direito e esquerdo houve fácil localização e colocação dos eletrodos, assim como o reto abdominal, pois ambos músculos possuem padronização de aplicação dos eletrodos pelo SENIAM.

As origens do músculo diafragma ficam próximas a outros músculos, tais como intercostais, reto do abdômen, oblíquos internos e externos. Com essa proximidade de vários músculos torna-se difícil isolar os sinais do músculo diafragma.

O diafragma esquerdo, apresenta maior grau de dificuldade em comparação ao lado direito, devido ao bombeamento sanguíneo e alta contratilidade do coração. Após testar a localização do sexto espaço intercostal, do sétimo espaço intercostal, constatou-se que o sétimo espaço intercostal é o espaço de mais eficiência para se obter a captura de sinais do músculo do diafragma esquerdo.

Discussão

Na literatura não há um protocolo estabelecido para a localização dos eletrodos. A SENIAM não possui recomendações para o uso do EMG nos músculos respiratórios [9]. A eletromiografia pode ser um exame com muitas vantagens, mas para avaliação diafragmática pode haver abrangência de mais de uma unidade motora, por ser um músculo profundo a proximidade de músculos na inserção do diafragma podem comprometer o sinal adquirido por contaminação, a gordura abdominal subcutânea pode dificultar a captação de sinal, alterações posturais também dificultam a fixação dos eletrodos [9, 10].

Muitos estudos elegem o posicionamento dos eletrodos no diafragma de acordo com o conhecimento anatômico do pesquisador. Na literatura há artigos que contemplam o posicionamento dos eletrodos no diafragma em EMGs, e cada um desses artigos trazem posicionamentos diferentes. Porém locais próximos [8, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34].

O tórax é uma região que por conter órgãos vitais importantes em constante funcionamento se apresenta com temperatura um pouco mais elevada que o restante do corpo e com isso a transpiração dessa área ocorre com frequência dificultando a aderência do eletrodo no tórax e consequentemente a captação adequada de sinais. O suor é condutivo, pode estabelecer contato entre eletrodos próximos [35].

A alteração postural é um desafio na colocação dos eletrodos, pois nos idosos do estudo por serem portadores da doença de Parkinson apresentavam a camptocormia e com isso o excesso de pele e rachadura afetam a textura da pele. Os eletrodos de superfície são

colocados na pele e a alteração postural pode causar deslocamento após o eletrodo ser posicionado.

O EMG pode ser usado também de forma invasiva, com o uso do eletrodo intramuscular onde seu formato é em forma de agulha, fio ou até mesmo gancho [9]. Seria uma forma de minimizar a dificuldade na análise da excursão diafragmática. Porém é importante ressaltar a dificuldade na fixação dos eletrodos, pois tal técnica é dolorosa, desconfortável e por ser invasiva acarreta em riscos para o paciente [36].

Conclusão

Os estudos que fazem uso do EMGs para avaliar os músculos respiratórios apresentam limitação da técnica por não haver consenso para posicionamento dos eletrodos. O estado da arte atual, compromete comparações da excursão diafragmática quando se utiliza o EMG de superfície [37].

Estudos que apontem a dificuldade em se avaliar a excursão diafragmática por meio do uso do EMG são necessários, pois podem fornecer uma base para que diretrizes sejam criadas visando otimizar estudos onde se faz necessária a avaliação do músculo diafragma. A criação de um protocolo para aplicabilidade dos eletrodos para análise do diafragma se faz necessário, dessa forma estudos poderão ser comparados e realizados de forma que não haja divergência entre as técnicas [37].

Referências

- [1] Merletti R.; Rainoldi A.; Farina D. Surface electromyography for noninvasive characterization of muscle. *Exercise and sport sciences reviews*, 2001; 29 (1): 20-25 .
- [2] Cray MA, Carnaby GD, Groher ME. Biomechanical correlates of surface electromyography signals obtained during swallowing by healthy adults. *J Speech Lang Hear Res*. 2006; 49(1):186-93.
- [3] Watanabe, K. Cross-talk from adjacent muscle has a negligible effect on surface electromyographic activity of vastus intermedius muscle during isometric contraction. *Journal of Electromyography Kinesiology*. 2009; 19(4): 280-289.
- [4] Souchard PE. Anatomia descritiva. In: Souchard PE. O diafragma 3rd ed. São Paulo: Summus, 1989, p.12-14.
- [5] Laghi F, Tobin MJ. Disorders of the respiratory muscles. *Am J Respir Crit Care Med*. 2003 1;168(1):10-48.
- [6] Campos PS. Avaliação da excursão diafragmática em um modelo experimental da doença de Parkinson [dissertação] Brasília: Universidade de Brasília; 2015.
- [7] Duranti R, Misuri G, Gorini M, Goti P, Gigliotti F, Scano G. Mechanical loading and control of breathing in patients with severe chronic obstructive pulmonary disease. *Thorax*. 1995; 50(2): 127-33.
- [8] Doherty KM, van de Warrenburg BP, Peralta MC, Silveira-Moriyama L, Azulay JP, Gershanik OS, et al. Postural deformities in Parkinson's disease. *Lancet Neurol*. 2011;10:538-49.
- [9] ATS/ERS. American Thoracic Society/European Respiratory Society statement on respiratory muscle testing. *Am. J. Respir. Crit. Care Med*. 2002; 166(4):518-624.

Anais do V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica - ISBN: 978-85-5722-065-2 - DOI: 10.29327/cobeceseb.78924

- [10]Luo, YM, Moxham J, Polkey MI. Diaphragm electromyography using an oesophageal catheter: current concepts. *Clin Sci*. 2008; 115(7-8):233-44.
- [11]White JE, Drinnan MJ, Smithson AJ, Griffiths CJ, Gibson GJ. Respiratory muscle activity during rapid eye movement (REM) sleep in patients with chronic obstructive pulmonary disease. *Thorax*. 1995; 50(4): 376-82.
- [12]Zattara-Hartmann MC, Badier M, Guillot C, Tomei C, Jammes Y. Maximal force and endurance to fatigue of respiratory and skeletal muscles in chronic hypoxemic patients: the effects of oxygen breathing. *Muscle nerve*. 1995; 18(5): 495-502.
- [13]Meessen NE, van der Grinten CP, Luijckendijk SC, Folgering HT. Histamine induced bronchoconstriction and end tidal inspiratory activity in man. *Thorax*. 1996; 51(12): 1192-8.
- [14]McEvoy RD, Popovic RM, Saunders NA, White DP. Effects of sustained and repetitive isocapnic hypoxia on ventilation and genioglossal and diaphragmatic EMGs. *J Appl Physiol* (1985). 1996; 81(2): 866-75.
- [15]Tzelepis GE, Zakynthinos S, Vassilakopoulos T, Geroulanos S, Roussos C. Inspiratory maneuver effects on peak expiratory flow. Role of lung elastic recoil and expiratory pressure. *Am J Respir Crit Care Med*. 1997; 156(5): 1399-404.
- [16]Field SK, Evans JA, Price LM. The effects of acid perfusion of the esophagus on ventilation and respiratory sensation. *Am J Respir Crit Care Med*. 1998 Apr;157(4 Pt 1):1058-62.
- [17]Lake FR, Finucane KE, Hillman DR. Diaphragm inhibition with positive pressure ventilation: quantification of mechanical effects. *Respiration physiology*. 1999; 118(2-3): 149-61.
- [18]Worsnop C, Kay A, Kim Y, Trinder J, Pierce R. Effect of age on sleep onset-related changes in respiratory pump and upper airway muscle function. *J Appl Physiol* (1985). 2000; 88(5): 1831-9.
- [19]Serra A, Polese G, Braggion C, Rossi A. Non-invasive proportional assist and pressure support ventilation in patients with cystic fibrosis and chronic respiratory failure. *Thorax*. 2002; 57(1): 50-4.
- [20]Jounieaux V, Parreira VF, Aubert G, Dury M, Delguste P, Rodenstein DO. Effects of hypocapnic hyperventilation on the response to hypoxia in normal subjects receiving intermittent positive-pressure ventilation. *Chest*. 2002; 121(4): 1141-8.
- [21]Ergun P, Aydin G, Turay UY, Erdogan Y, Caglar A, Biber C. Short-term effect of nasal intermittent positive-pressure ventilation in patients with restrictive thoracic disease. *Respiration*. 2002; 69(4): 303-8.
- [22]Puckree T, Cerny F, Bishop B. Does Intercostal Stretch Alter Breathing Pattern and Respiratory Muscle Activity in Conscious Adults? *Physiotherapy*. 2002; 88(2): 89-97.
- [23]Duijverman ML, van Eykern LA, Vennik PW, Koeter GH, Maarsingh EJ, Wijkstra PJ. Reproducibility and responsiveness of a noninvasive EMG technique of the respiratory muscles in COPD patients and in healthy subjects. *J Appl Physiol* (1985). 2004; 96(5): 1723-9.
- [24]Reynaud-Gaubert M, Guillot C, Faucher M, Jammes Y, Fuentes P, Badier M. Increased diaphragmatic strength and tolerance to fatigue after bilateral lung transplantation: an electromyographic study. *J Electromyogr Kines*. 2004; 14(2): 179-85.
- [25]Stoohs RA, Blum HC, Knaack L, Butsch-von-der-Heydt B, Guilleminault C. Comparison of pleural pressure and transcutaneous diaphragmatic electromyogram in obstructive sleep apnea syndrome. *Sleep*. 2005; 28(3): 321-9.
- [26]de Andrade AD, Silva TN, Vasconcelos H, Marcelino M, Rodrigues-Machado MG, Filho VC, et al. Inspiratory muscular activation during threshold therapy in elderly healthy and patients with COPD. *J Electromyogr Kines*. 2005; 15(6): 631-9.
- [27]Knaack L, Blum HC, Hohenhorst W, Ryba J, Guilleminault C, Stoohs RA. Comparison of Diaphragmatic EMG and Oesophageal Pressure in Obstructed and Unobstructed Breathing during Sleep. *Somnologie*. 2005;9:159-65.
- [28]Alonso JF, Mananas MA, Hoyer D, Topor ZL, Bruce EN. Evaluation of respiratory muscles activity by means of cross mutual information function at different levels of ventilatory effort. *IEEE Trans Biomed Eng*. 2007; 54(9): 1573-82.
- [29]Hawkes EZ, Nowicky AV, McConnell AK. Diaphragm and intercostal surface EMG and muscle performance after acute inspiratory muscle loading. *Respir Physiol Neurobiol*. 2007; 155(3): 213-9.
- [30]Eckert DJ, McEvoy RD, George KE, Thomson KJ, Catcheside PG. Effects of hypoxia on genioglossus and scalene reflex responses to brief pulses of negative upper-airway pressure during wakefulness and sleep in healthy men. *J Appl Physiol* (1985). 2008; 104(5): 1426-35.
- [31]Chien MY, Wu YT, Lee PL, Chang YJ, Yang PC. Inspiratory muscle dysfunction in patients with severe obstructive sleep apnoea. *European Respir J*. 2010; 35(2): 373-80.
- [32]Segizbaeva MO, Pogodin MA, Lavrova IN, Balykin MV, Aleksandrova NP. Effect of head-down tilt on respiratory responses and human inspiratory muscles activity. *Human Physiol*. 2011; 37(2): 52-9.
- [33]Da Gama AE, de Andrade Carvalho L, Feitosa LA, do Nascimento Junior JF, Da Silva MG, Amorim CF, et al. Acute effects of incremental inspiratory loads on compartmental chest wall volume and predominant activity frequency of inspiratory muscle. *J Electromyogr Kines*. 2013; 23(6): 1269-77.
- [34]Porszasz J, Cao R, Morishige R, Van Eykern LA, Stenzler A, Casaburi R. Physiologic effects of an ambulatory ventilation system in chronic obstructive pulmonary disease. *Am J Respir Crit Care Med*. 2013; 188(3): 334-42.
- [35]Basmajian J. & De Luca C. *Muscles alive. Their functions revealed by electromyography*. 5th ed., Baltimore: William & Wilkins, 1985. 561p.
- [36]Hutten GJ, Van Thuijl HF, Van Bellegem ACM, Van Eykern LA & Van Aalderen WMC. A literature review of the methodology of EMG recordings of the diaphragm. *Journal of Electromyogr Kinesiology*. 2010; 20(2):185-90.
- [37]Moher D, Shamseer L, Clarke M, Ghersi D, Liberati A, Petticrew M, Shekelle P, Stewart LA and PRISMA-P Group. Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. *Systematic reviews*, 4(1), 1.

APÊNDICE F – ARTIGO COMPLETO 4 CBEB 2018

Predicting knee angles from video: an initial experiment with Machine Learning

Guimarães, I.J.A.¹[0000-0002-1303-3317]; Lopes, R.M.²; Junior, J.F.L.S.¹[0000-0002-0874-6056],
Sousa, B.S.¹; Marães, V.R.F.S.^{1,2} and Brasil, L.M.¹[0000-0002-7437-107X]

¹ Universidade de Brasília (UnB) at Gama, Post-Graduation Program in Biomedical Engineering, Brasília - DF, Brazil

² Universidade de Brasília (UnB) at Ceilândia, Brasília - DF, Brazil
ithallojunior@outlook.com

Abstract. Machine Learning (ML) has drawn a lot of attention these days due to its capability to automate processes that were very complicated and/or only performed by humans before. It is done by not having the need to write hard coded rules to solve problems, letting the machine find the rules by itself, and for being able to universally approximate functions with certain algorithms. On the other side, motion capture systems are quite expensive, making it more difficult to health professionals and physicians to have a more precise way to analyze the gait of patients and the diseases related to it. Having that said, this paper aimed to show that is possible to predict (generate) the angles of the right knee of patients directly from a common video of their walks, reducing costs and opening the opportunity for a more complete and affordable system to realize motion capture. Thus, this study is an initial experiment and the first step towards a possible future more complete product. As an initial study, the data of three patients were acquired and the resulting model, a Multilayer Perceptron Artificial Neural Network (MLP), acquainted a score of 92.2% when predicting the angles of the right knee for unknown data.

Keywords: Machine Learning (ML), Multilayer Perceptron (MLP), Knee Angles.

1 Introduction

The biomechanics of the musculoskeletal system of the human body has been studied over many years as an attempt to better understand the behavior and interactions between its components. The joints knees, hip and intervertebral discs are the components of the human body traditionally studied by the variability and complexity of the problems that affect them.

According to [1], numerous studies at the computational level have been developed to try to translate the biomechanical behavior of the knee joint, and to perceive the problems that affect this joint. Works, like the ones of [2] and [3], developed analytical models of the knee in the sagittal plane to study the effect of ligaments on joint

2

control and forces, as well as there is a three-dimensional knee model using finite elements that was developed by [4]. In this context, the use of a computer aid and automation seems reasonable, having that been said, the idea of ML and its techniques comes easily to mind, because of the variety of their potential uses in Biomedical Engineering and related fields.

1.1 Machine Learning and Artificial Neural Networks

ML is defined by [5] as a set of techniques which can detect patterns in data, then, using these uncovered, predict the future data, or even to perform different kinds of decision making under uncertainty.

ML can be divided into three main types: supervised learning, unsupervised learning and reinforcement learning. According to [5] and [6], it can be defined as follows: supervised learning uses a determined set of known (labeled) input-output pairs (training set) in order to train the algorithm; unsupervised learning, in an opposite way, does not know beforehand the outputs for given inputs (unlabeled data or unknown structure of data) and it is used to find patterns and meaningful information in data without the usage of an obvious error metric; by last, reinforcement learning is said use reward or punishment signal (feedbacks for measures of how well the system behaved) in order to improve the performance of the system based on its interactions with the “environment”.

Bearing in mind the context of ML, this paper wants to use a feed-forward MLP to get continuous values (regression). This algorithm fits under the supervised type of learning.

MLP is said to be an artificial neural network (ANN) that can solve nonlinearly separable problems, which includes a nonlinear separable activation function, contains one or more “hidden” layers (in between the input and output), and a high degree of “connectivity” (its extent is determined by its synaptic weights) [7].

The use of ANNs and their capabilities is demonstrated by the works of [8] and [9], which have shown the use of two different kinds of ANNs (a Cerebellar Model Articulation Control and an MLP, respectively) to predict the angular velocities of human knee from signals of the contralateral knee [8] and from some signals of both knees [9].

This paper follows the aforementioned works, but takes a different approach. It aims to develop an automated system to predict the angles of the knee using only the video frames of the walks and, therefore, to help physicians and health-related professionals that have to use motion capture systems on their works.

1.2 Human Gait

Human gait is characterized by a sequence of multiple fast and complex events, so clinical observation, identification of changes in phenomena, and observation of their degree of withdrawal from normal become difficult [10]. It is a repetitive sequence of a movement of subordination to movement. In the gait a member acts as a moving

3

support, in contact as solo as the opposing member advances it in the air, the set of tasks that can be repeated cyclically and the members of their roles at every step [11]. The Fig. 1 shows the human gait in a complete cycle.




Fig. 1. Human gait. Adapted from [11].

Many patients may benefit from instrumented gait analysis, including: cerebral palsy, cranioccephalic trauma, neuromuscular diseases, traumatic spinal cord injuries, congenital and lower limb amputations. The instrumented gait analysis is used to aid in oncologic surgery, physical therapy programs, use of peripheral neuromuscular blocks, indication and adequacy of orthotics and prostheses. Although this analysis is carried out in several laboratories in several countries, it is still not very widespread in Brazil. And the main factor limiting its diffusion is the high cost of commercial systems available [11].

One of the most studied joints during gait analysis is that of the knee. It has a very complex structure and is also one of the most susceptible to involvement by various lesions. Thus, the quantification of movement and the detection of changes not perceived by the naked eye add many advantages to research and understanding of gait [10].

2 Materials and Methods

As this paper is based on previous works of [8] and [9], its materials and methods follow a similar fashion, having some changes due to the different nature of this work. It is presented as follows.

2.1 Data acquisition

The data used were obtained from three patients on the Human Performance Laboratory at Faculty UnB-Ceilândia, University of Brasília (UnB). The patients were young males, who repeated a walk of five seconds for few times in front the system,

4

all the walks were required to start at the same point and angle to the cameras, in order to homogenize the data and prevent random fluctuations.

The system used was the Qualisys Oqus MRI and the Qualisys QTM 3.2 software package, this system was composed of twelve cameras to acquire the position of the body markers. Nine passive body markers were distributed along the inferior limbs of the subject and another camera was synced to the system to record the video of the walks.

The cameras used to acquire the body markers' positions had a frame rate of 200 frames per second (fps) and the one used to record video had one of 30 fps and a resolution of 640 by 480 pixels.

This data acquisition process was approved by the Health Sciences Faculty Ethics Committee from UnB, protocol number 38386714.8.0000.0030 on March 11, 2016.

2.2 Preprocessing

Not all the data acquired were used for the predictions. Firstly, only the data from the points marked as knee, trochanter and tibia were selected and they were fitted into one gait cycle. The walks that contained invalid data points inside the gait cycle were discarded. The data visualization and marker number selection were made utilizing the system developed by [12], in which a gait analysis and simulation system was created.

After defining the beginning and the end of the gait cycles, the videos were trimmed to fit that duration, had its colors removed and cut, in order to remove unnecessary data (such as the hands of the patients) and focus on the moving legs. It resulted in frames with a resolution of 200 by 250 pixels. The conversion of the video into vectors was made utilizing a Python library for video processing called Scikit-video, which provides easily accessible tools for reading and writing videos with Python. Those values were chosen because they were the ones that more accurately fitted the beginning and the ending of a gait cycle. The Fig. 2 shows the initial and final frames after preprocessing.

After this process, the data selected were passed on to the kinematics calculations.




Fig. 2. Initial and final frames of a gait cycle after video preprocessing.

2.3 Kinematic Calculations

Python (2.7.12) was used for these computation processes. In these processes, Python libraries such as SciPy and Numpy inside an Anaconda environment were used in order to read and process the data. Then, angles of the knees were calculated for both legs. Equation (1) [13] shows how the angles were obtained using trochanter, knee and tibia.

$$\theta = \cos^{-1} \frac{u \cdot v}{|u| |v|} \quad (1)$$

The knee was used as origin of the system, and then relative positions of the other points were calculated using it. After this, the angles could be calculated using (1). In order to make this work more feasible, only the right knee angles were selected to be used in this initial experiment.

2.4 Algorithm used

The MLP algorithm was chosen because of its capacities of being a universal approximator, provided that enough hidden nodes are available, as established by [14].

The purpose of this paper is not to develop a state of the art ML technique, but to show the possibilities of its use, because of it, the Scikit-learn (version 0.19) Python package [15] was used instead of developing it all over. That package provides the state of the art algorithms for ML, metrics for the quality and preprocessing for the data [15].

2.5 Implementation details

This paper aimed to show that the video record of a walk could be used to get the angles of the knee during that, for this reason, the video frames were used as inputs and the knee angle as output. Only the right leg was used for this implementation.

To use the videos as inputs, its 200 by 250 pixels of about 41 frames per gait cycle were reshaped into strings of 50,000 data points per frame. As there was a difference between the number of output points and the input frames, because of the different frame rates, the knee angles outputs were resampled evenly accordingly.

The data from the gait cycles were split randomly into three groups: one for training, a second and validating the model and improving the results that would be obtained, and a third for testing the model after its implementation.

The datasets were separated using a function from the Sci-kit-learn package [15] and kept the proportion of 70% for training and 15% for validating, and, 15% for testing, randomly separated. After splitting the data, the groups were scaled up using another Scikit-learn library [15] in order to speed up the convergence process.

The MLP used had two hidden layers of 10 and 15 nodes respectively, used the hyperbolic tangent function as nonlinear activation function, and was run for 1000 iterations each time it was validated. Those parameters were selected empirically for being the ones that provided the best results when tinkering with the problem.

6

3 Results and Discussion

After testing many different configurations for the MLP using the validation set to improve the result and settling down the values established in the previous section, a score of 92.2% (or 0.922 as it can go up to 1) was obtained from the test dataset, demonstrating that it is perfectly possible to predict joint angles from a video input.

That score was calculated using the coefficient of determination (R^2 score) which shows to what degree the predictions of the regression model surpass the predictions based on the mean value of the desired output, this way, it provides a measure of how well future samples are likely to be predicted by the model. In that coefficient, the closer it gets to 1 the better it is, it can be negative as well (as the results of the model could be arbitrarily worse) [16, 17]. Equation (2) shows how the score could be calculated, where \hat{y}_i represents the value predicted by the i -th input sample, y_i is the actual result of that i -th sample, and \bar{y} shows the mean value of y for a number n of samples.

$$R^2 y, \hat{y} = \frac{\sum_{i=1}^{n-1} (y_i - \bar{y})^2}{\sum_{i=1}^{n-1} (\hat{y}_i - \bar{y})^2} \quad (2)$$

The strength of the results were also tested out using the explained variance score, this latter score measures to what proportion a mathematical model responds to changes (dispersion) of a certain dataset [16, 17]. In this score, the closer to 1 the better it is as well. The model had a score of 93.2% (or 0.932).

Fig. 3 shows the relationship between the predicted results and the test dataset. It should be noted that it does not have the usual shape of the knee angles because of the way the data were divided, but it is useful to see the relationships of the results.

According to [18], one of the most studied joints is that of the knee because of its importance in human gait. Positive effects were evidenced by [19], the results found conclude that it is possible to perform analysis of the human gait by the video system, with the possibility of analyzing joints.

Accuracy may have been affected by the small sample size, associated with the heterogeneity of the studied group. These two factors prevented the stratified analysis of some inclusion factors, such as sex, age and pathologies, which could be considered a limitation of this research, but these results, however, are the starting point for future studies involving a larger sample.

7




Fig. 3. Similarity of predicted data and actual test data.

4 Conclusion and final thoughts

This paper demonstrated the use of an ML technique (an MLP) to predict the angles of a human knee from the video frames. The results obtained were very satisfactory as an initial experiment, showing that the internal relations of their input and output could be used in the future as a tool to assist professionals who cannot use a high cost system of motion capture.

Future works could include different ML techniques, such as Support Vector Machines (SVM) and deep learning, or even a comparison between the three of them. As it is thought to be an aid to health professionals and physicians, a better user interface must be developed.

In addition, with a more medical-oriented approach, this study would also aid in more accurate diagnoses with a promising prognosis to prevent injury and improve performance.

5 Conflict of interests

The authors declare that there is no conflict of interests with this paper.

6 Acknowledgements

The first author would like to thank the Informatics Laboratory in Health (ILH) from UnB at Gama and the Human Movement Laboratory of UnB at Ceilândia for the resources given and also the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) for the scholarship given to the first author.

8

References

1. Peña E., Calvo B., Doblaré, M.: Biomecánica de la articulación de la rodilla tras lesiones ligamentosas. *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería* 22(1), 63-78 (2006).
2. Chan, S.C., Seedhom, B.B.: The effect of the geometry of the tibia on prediction of the cruciate ligament forces: A theoretical analysis. In: *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine* 209(1), 17–30 (1995).
3. Beynon, B. et al: A sagittal plane model of the knee and cruciate ligaments with application of a sensitivity analysis, *Journal of Biomechanical Engineering* 118(2), 227–239 (1996).
4. Bendjaballah, M. Z., Shirazi-adl, A., Zukor, D. J.: Biomechanical response of the passive human knee joint under anterior-posterior Forces. *Clinical Biomechanics* 13(8), 625–633 (1998).
5. Murphy, K.P.: *Machine Learning: A Probabilistic Perspective*. The MIT Press, Cambridge, Massachusetts (2012).
6. Raschka, S.: *Python Machine Learning*. Packt Publishing, Birmingham (2015).
7. Haykin, S.: *Neural Networks and Learning Machines*. 3rd edition. Pearson Prentice Hall, New York (2008).
8. Lima, R.A. et al: Human Knee Simulation Using CMAC ANN. In: D.A. Jaffray (ed.), *World Congress on Medical Physics and Biomedical Engineering* (2015).
9. Guimarães, I.J.A. et al: Human knee simulation using multilayer perceptron artificial neural network. In: *XXV Congresso Brasileiro de Engenharia Biomédica* (2016).
10. Leite, N.M., Faloppa, F.: *Propedêutica Ortopédica e Traumatologia*. Artmed, Porto Alegre (2013).
11. Perry, J., Burnfield, J.M.: *Gait Analysis: Normal and Pathological Function*. Slack, Thorofare, N. J. (2010).
12. Aguiar L.R.: *Implementando um Software como Serviço para Análise e Simulação de Marcha Humana*. MSc dissertation, Universidade de Brasília (UnB), Gama, DF (2015).
13. Larson R., Edwards B.H.: *Multivariable Calculus*. 9th ed. Brooks/cole, Belmont (2010).
14. Hornik, k.: Approximation Capabilities of Multilayer Feedforward Networks. In: *Neural Networks*, vol. 4, pp. 251-257. Pergamon Press PLC (1991).
15. Pedregosa et al.: Scikit-learn: Machine Learning in Python. In: *JMLR* 12, pp. 2825-2830 (2011).
16. Glantz, S.A.; Slinker, B.K.: *Primer of Applied Regression and Analysis of Variance*. McGraw-Hill (1990).
17. Nagelkerke, N.J.D.: A Note on a General Definition of the Coefficient of Determination. In: *Biometrika* vol. 78 (3): 691–692 (1991).
18. Souza, F.C.S.: *Avaliação de Joelho Mecânico para Amputados*. MSc Dissertation, Universidade de Brasília, Brasília, DF (2014).
19. Araújo, A.G.N., Andrade, L.M., Barros, R.M.L.: Sistema para análise cinemática da marcha humana baseado em videogrametria. In: *Fisioterapia e Pesquisa* vol. 2 pp. 3-10 (2005).