

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE ENGENHARIA ELÉTRICA  
PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
LABORATÓRIO DE ENGENHARIA BIOMÉDICA**

**AVALIAÇÃO DO DESEMPENHO DE CLASSIFICADORES  
NA DISCRIMINAÇÃO DE INDIVÍDUOS ADULTOS E IDOSOS  
SAUDÁVEIS A PARTIR DA FUNÇÃO MANUAL**

**Gabriella Lelis Silva**

**Orientador: Prof. Adriano Alves Pereira**

**Uberlândia-MG  
2023**

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE ENGENHARIA ELÉTRICA  
PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
LABORATÓRIO DE ENGENHARIA BIOMÉDICA**

**AVALIAÇÃO DO DESEMPENHO DE CLASSIFICADORES  
NA DISCRIMINAÇÃO DE INDIVÍDUOS ADULTOS E IDOSOS  
SAUDÁVEIS A PARTIR DA FUNÇÃO MANUAL**

**Gabriella Lelis Silva**

Tese de doutorado apresentado ao programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como parte dos requisitos para obtenção do título de Doutora em Ciência.

**Uberlândia-MG  
2023**

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

---

S586a  
2023      Silva, Gabriella Lelis, 1990-  
            Avaliação do desempenho de classificadores na discriminação de indivíduos adultos e idosos saudáveis a partir da função manual [recurso eletrônico] / Gabriella Lelis Silva. - 2023.

            Orientador: Adriano Alves Pereira.  
            Tese (Doutorado) - Universidade Federal de Uberlândia, Programa de Pós-Graduação em Engenharia Elétrica.

            Modo de acesso: Internet.

            Disponível em: <http://doi.org/10.14393/ufu.te.2023.7042>

            Inclui bibliografia.

            1. Engenharia elétrica. I. Pereira, Adriano Alves, 1964-, (Orient.). II. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

---

CDU: 621.3

Glória Aparecida  
Bibliotecária Documentalista - CRB-6/2047



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA**  
 Coordenação do Programa de Pós-Graduação em Engenharia Elétrica  
 Av. João Naves de Ávila, 2121, Bloco 3N - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902  
 Telefone: (34) 3239-4707 - www.posgrad.feelt.ufu.br - copel@ufu.br



### ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Elétrica				
Defesa de:	Tese de Doutorado, 320, PPGEELT				
Data:	Dezesseis de junho de dois mil e vinte e três	Hora de início:	08:00	Hora de encerramento:	10:00
Matrícula do Discente:	11723EEL011				
Nome do Discente:	Gabriella Lelis Silva				
Título do Trabalho:	Avaliação do desempenho de classificadores na discriminação de indivíduos adultos e idosos saudáveis a partir da função manual				
Área de concentração:	Processamento da Informação				
Linha de pesquisa:	Processamento Digital de Sinais e Redes de Computadores				
Projeto de Pesquisa de vinculação:	Coordenador do projeto: Adriano Alves Pereira Título do projeto: Caracterização da rigidez em pessoas com a doença de Parkinson por meio de uma órtese de punho Agência financiadora: CNPQ Número do processo na agência financiadora: 309525/2021-7 Vigência do projeto: 28/02/2026.				

Reuniu-se por meio de videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Keiji Yamanaka - FEELT/UFU; Fernando Pasquini Santos - FEELT/UFU; Lacordaire Kemel Pimenta Cury - IF Goiano; Guilherme Bernardino da Cunha - UFSM; Adriano Alves Pereira - FEELT/UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Adriano Alves Pereira, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Fernando Pasquini Santos, Professor(a) do Magistério Superior**, em 16/06/2023, às 10:11, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Adriano Alves Pereira, Professor(a) do Magistério Superior**, em 16/06/2023, às 10:11, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Keiji Yamanaka, Professor(a) do Magistério Superior**, em 16/06/2023, às 10:12, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Lacordaire Kemel Pimenta Cury, Usuário Externo**, em 16/06/2023, às 10:12, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Guilherme Bernardino da Cunha, Usuário Externo**, em 16/06/2023, às 10:12, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [https://www.sei.ufu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **4571925** e o código CRC **946794C3**.

# AGRADECIMENTOS

À DEUS, que se faz presente em todos os momentos da minha vida, por ter colocado pessoas incríveis no meu caminho, pelas oportunidades vividas, pelas batalhas vencidas e por todos os momentos felizes que tive até aqui e os tristes que muito me ensinaram.

À minha família, em especial aos meus pais, Jairo e Simone, por sempre acreditarem que eu seria capaz de concluir mais essa etapa da minha vida, obrigada pela confiança e por depositarem todo amor desde sempre. À minha irmã, Izabella, que é a minha base, minha inspiração, meu exemplo de ser humano, que está sempre por perto, incentivando e apoiando minhas escolhas. Ao meu marido, Yuri, pelo amor, cuidado, incentivo e apoio necessário para que eu conseguisse concluir mais essa etapa da minha vida, à minha filha Isabel, por ser meu grande amor e minha principal fonte de inspiração. E aos demais familiares, avó, tios, primos, por todo cuidado e preocupação que sempre tiveram comigo.

À todos os meus amigos, em especial a Cassiana, por todo suporte, paciência e auxílio, não só em relação ao doutorado, como questões da minha vida pessoal, e a Carol e Camilla, por serem minhas parceiras de vida desde sempre.

À Universidade Federal de Uberlândia (UFU), à Faculdade de Engenharia Elétrica, ao curso de Pós-Graduação em Engenharia Biomédica (PPGEB), ao Laboratório de Pesquisa do Núcleo de Inovação e Avaliação Tecnológica em Saúde (NIATS), pelo apoio e a disponibilização dos recursos necessários para a realização desta pesquisa.

Ao meu professor e orientador Dr Adriano Alves Pereira, pela atenção, cuidado, apoio e incentivo durante toda a realização deste trabalho. Agradeço por sempre depositar em mim confiança na realização de nossos trabalhos, sem medir esforços para a concretização de mais uma etapa importante da minha vida.

À Maria José Ferreira Zaruz, pelo auxílio e disponibilidade dos dados, os quais foram feitos de forma impecável para que esse e outros trabalhos fossem concluídos com sucesso.

Aos voluntários que se dispuseram a contribuir com a ciência, possibilitando a conclusão de diversos trabalhos extremamente importantes para a sociedade.

À CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pela concessão da bolsa durante o período de realização deste doutorado.

“Agradeço todas as dificuldades que enfrentei.  
Não fossem por elas, eu não teria saído do lugar.  
As facilidades nos impedem de caminhar.  
Mesmo as críticas nos auxiliam muito.”

**Chico Xavier**

# RESUMO

A identificação de características que auxiliam na avaliação de processos relacionados ao envelhecimento é um assunto cada vez mais estudado. O uso de biomarcadores e ferramentas que oferecem maior especificidade e sensibilidade para quantificar e caracterizar tarefas motoras, ajuda a compreender as mudanças biológicas ocorridas devido ao avanço da idade, podendo prever fenótipos relacionados à idade ou desfecho de saúde. Como proposta deste estudo, têm-se como objetivo avaliar o desempenho de diferentes classificadores na discriminação de indivíduos adultos e idosos saudáveis a partir da caracterização da função manual, utilizando sensores inerciais. **Método:** Foram recrutados 99 participantes saudáveis, com faixa etária entre 20 a 98 anos. A coleta de dados foi realizada por meio de sensores inerciais, posicionados no dorso e região posterior da mão dominante. Os indivíduos realizaram três tarefas sequenciais com o antebraço flexionado, (i) repouso, (ii) pinça polpa a polpa e (iii) supinação/pronação. Diferentes características foram extraídas dos sinais para serem utilizadas na comparação dos valores da especificidade, sensibilidade, precisão e acurácia. Os algoritmos Floresta Aleatória (RF), Máquina Vetor Suporte (SVM), K-vizinho mais próximo (KNN) e Naive Bayes (NB) foram utilizados para classificar os grupos. **Resultados:** Através das características extraídas dos sensores inerciais da mão dominante dos voluntários, o algoritmo que apresentou o melhor desempenho em relação à sensibilidade foi o SVM quando alimentado com 25% das características, com uma taxa de 89.6%. O classificador RF foi o que obteve melhor especificidade (72.8%) quando alimentado com todas as características. Já o NB obteve melhor precisão e acurácia (75.5% e 79.3% respectivamente) quando alimentado com 60% das características. **Conclusão:** Os resultados obtidos nesse estudo demonstram que o uso de algoritmos de classificação da *machine learning* na discriminação de grupos adultos e idosos saudáveis, com altas taxas de sensibilidades e especificidades, fornece informações valiosas para avaliações clínicas a partir da previsão de alterações motoras relacionadas ao avanço da idade diante da caracterização de tarefas motoras.

**Palavras-Chave:** Envelhecimento humano, sensores inerciais, classificadores.

# ABSTRACT

The identification of features that aid in the assessment of processes related to aging is an area of ever-increasing study. The use of biomarkers and tools that offer greater specificity and sensitivity to quantify and characterize motor tasks, aid in the understanding of biological changes that occur due to advancing age, and as such predefined phenotypes related to age or health outcomes. The proposal behind this study is thus to assess the performance of different classifiers in the discrimination of both healthy individual adults and senior citizens from the characterization of functional fitness tasks, using inertial sensors. **Method:** Ninety-nine healthy participants were recruited, with ages ranging from 20 to 98 years old. The collection of data was performed by means of two inertial measurement units (IMUs), positioned in the region of the distal third of the forearm of the dominant hand and on the back of the dominant hand. The participants performed three successive tasks with the forearm flexed, (i) at rest, (ii) pulp to pulp pinch, and (iii) supination/pronation. Different features were extracted from the signals that were then used in the comparison of the values for specificity, sensitivity, precision, and accuracy. The classifiers random forest (RF), support vector machine (SVM), k-nearest neighbor (KNN), and naive Bayes (NB) were used to classify the groups. **Results:** Through use of the features extracted by the IMUs in the region of the distal third of the forearm of the dominant hand, and on the back of the dominant hand of the volunteers, the classifier that presented the best sensitivity was the SVM, when fed with 25% of the features, with a rate of 89.6%. The RF classifier was the one that obtained the best specificity (72.8%), when fed with all the features. However, the NB obtained the best precision and accuracy (75.5% and 79.3% respectively), when fed with 60% of the features. **Conclusion:** The results obtained in this study demonstrate that the use of classification algorithms from machine learning in the discrimination of healthy adult and senior citizen groups, with high rates of sensitivity and specificity, provide valuable information for clinical assessment concerning the prediction of motor changes related to advancing age regarding the characterization of motor-related tasks.

**Keywords** Human aging · Inertial sensors · Classifier

# LISTA DE FIGURAS

Figura 2.1 - Pirâmide etária do Mundo. As barras coloridas indicam os dados de variantes médias, o sombreamento em cinza (mostrados nas figuras D, E e F) indica a incerteza, com intervalo de precisão de 95%. (A) População mundial em 1950. (B) População mundial em 1990. (C) População mundial em 2020. (D) Projeção da população mundial em 2030. (E) Projeção da população mundial em 2050. (F) Projeção da população mundial em 2100.....	26
Figura 2.2 - Pirâmide etária do Brasil. As barras coloridas indicam os dados de variantes médias, o sombreamento em cinza (mostrados nas figuras D, E e F) indica a incerteza, com intervalo de precisão de 95%. (A) População brasileira em 1950. (B) População brasileira em 1990. (C) População brasileira em 2020. (D) Projeção da população brasileira em 2030. (E) Projeção da população brasileira em 2050. (F) Projeção da população brasileira em 2100.....	27
Figura 3.1 - Fluxograma da realização do trabalho.....	44
Figura 3.2 - Hardware TREMSEN.....	47
Figura 3.3 - (A) Componentes do TREMSEN, 1 - cabo USB; 2 - Bateria EMG; 3 - Sensores Inerciais; 4 - Eletrodos EMG de superfície; (B) Placa MinIMU com Sensor de movimento.....	48
Figura 3.4 - Tela do software TREMSEN com visualização em tempo real.....	48
Figura 3.5 - Posicionamento dos sensores inerciais e direção dos eixos.....	49
Figura 3.6 - Janelamento do sinal utilizando o marcador de pulso. (Tarefa A) repouso com membro superior dominante; (Tarefa B) movimento de pinça polpa a polpa; (Tarefa C) movimento de supinação/pronação.....	50
Figura 4.1 - Sinal do acelerômetro 1 de um dos voluntários. (a) sinal no eixo x, (b) sinal no eixo y, (c) sinal no eixo z e, (d) sinal resultante correspondente.....	61
Figura 4.2 - Sinal do giroscópio 1 de um dos voluntários. (a) sinal no eixo x, (b) sinal no eixo y, (c) sinal no eixo z e, (d) sinal resultante correspondente.....	61
Figura 4.3 - Sinal do magnetômetro 1 de um dos voluntários. (a) sinal no eixo x, (b) sinal no eixo y, (c) sinal no eixo z e, (d) sinal resultante correspondente.....	62
Figura 4.4 - Sensibilidade dos classificadores em relação a porcentagem das características	63
Figura 4.5 - Especificidade dos classificadores em relação a porcentagem das características.....	63
Figura 4.6 - Precisão dos classificadores em relação a porcentagem das características.....	64
Figura 4.7 - Acurácia dos classificadores em relação a porcentagem das características.....	64

Figura 4.8 - Peso de cada um dos sensores quando os classificadores foram alimentados com 25% das características.....	67
Figura 4.9 - Peso de cada um dos sensores quando os classificadores foram alimentados com 60% das características.....	67
Figura 4.10 - Peso do grupo de características quando os classificadores foram alimentados com 25% das características.....	68
Figura 4.11 - Peso do grupo de características quando os classificadores foram alimentados com 60% das características.....	69
Figura 4.12 - Peso de cada uma das características quando os classificadores foram alimentados com 25% das características.....	70
Figura 4.13 - Peso de cada uma das características quando os classificadores foram alimentados com 60% das características.....	71
Figura 5.1 - Métricas dos classificadores alimentados com 25% das características.....	76
Figura 5.2 - Métricas dos classificadores alimentados com 60% das características.....	76
Figura 5.3 - Métricas dos classificadores alimentados com 100% das características.....	77

# LISTA DE TABELAS

Tabela 3.1 - Amostras dos grupos .....	46
Tabela 3.2 - Características demográficas dos participantes incluídos neste estudo.....	46
Tabela 3.3 - Quantidade de características extraídas.....	57
Tabela 3.4 - Matriz de confusão.....	58
Tabela 4.1 - Melhores resultados para as métricas dos classificadores.....	65
Tabela 4.2 - Peso de cada tarefa para classificação dos grupos .....	66
Tabela 4.3 - Peso de cada IMU para classificação dos grupos .....	66
Tabela 4.4 - Peso de cada sensor para classificação dos grupos .....	66
Tabela 4.5 - Peso das características para a classificação dos grupos .....	68
Tabela 4.6 - Peso de cada característica para a classificação dos grupos.....	69

# LISTA DE ABREVIATURAS E SIGLAS

UFU	Universidade Federal de Uberlândia
PPGEB	Programa de Pós Graduação em Engenharia Biomédica
NIATS	Núcleo de Inovação e Avaliação Tecnológica em Saúde
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
RF	Floresta Aleatória
SVM	Máquina Vetor Suporte
KNN	k-vizinho mais próximo
NB	<i>Naive Bayes</i>
ML	<i>Machine Learning</i>
OMS	Organização Mundial de Saúde
DP	Doença de Parkinson
AVDs	Atividades de Vida Diária
SNC	Sistema Nervoso Central
IMU	Unidade de Medição Inercial
DT	Árvore de Decisão
CONEP	Comissão Nacional de Ética em Pesquisa
TCLE	Termo de Consentimento Livre e Esclarecido
GA	Grupo Adulto
GI	Grupo Idoso
TREMSSEN	<i>Precise Tremor Sensing Technology</i>
INPI	Instituto Nacional da Propriedade Industrial
EMG	Eletromiografia
USB	<i>Universal Serial Bus</i>
TA	Tarefa A (repouso com membro superior dominante)
TB	Tarefa B (movimento de pinça polpa a polpa)
TC	Tarefa C (movimento de supinação/pronação)
R	Vetor Resultado
RMS	Raiz Média Quadrática
MAV	Valor Médio Absoluto

MAVFD	Valor Médio Absoluto da Primeira Diferença
MAVSD	Valor Médio Absoluto da Segunda Diferença
ZC	<i>Zero Crossing</i>
FPICO	Frequência de Pico
FMEDIA	Frequência Média
F50	Frequência Mediana
VAR	Variância
RANGE	Faixa de Amplitude
IntA	Intervalo Interquartil
ApEn	Entropia Aproximada
<i>FuzzyEn</i>	Entropia <i>Fuzzy</i>
TP	Verdadeiro Positivo
FP	Falso Positivo
FN	Falso Negativo
TN	Verdadeiro Negativo
IMU1	Unidade de Medição Inercial 1 (localizado na região do terço distal do antebraço da mão dominante)
IMU2	Unidade de Medição Inercial 2 (localizado no dorso da mão dominante)
A1	Acelerômetro da IMU1
A2	Acelerômetro da IMU2
G1	Giroscópio da IMU1
G2	Giroscópio da IMU2
M1	Magnetômetro da IMU1
M2	Magnetômetro da IMU2

# Sumário

<b>CAPÍTULO 1 - INTRODUÇÃO.....</b>	<b>18</b>
1.1 Motivação.....	18
1.2 Relevância da Tese .....	20
1.3 Objetivos da Pesquisa .....	21
1.3.1 Geral .....	21
1.3.2 Específicos.....	21
1.4 Hipótese .....	22
1.5 Produções realizadas durante o período de Doutorado .....	22
1.5.1 Produções publicadas em anais de congressos.....	22
1.5.2 Produções publicadas em anais de periódicos.....	23
1.5.3 Trabalhos técnicos realizados .....	24
<b>CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>25</b>
2.1 Envelhecimento Populacional .....	25
2.2 Características biológicas do envelhecimento humano .....	28
2.2.1 Alterações manuais devido ao avanço da idade .....	31
2.3 Tarefas motoras e suas utilizações nas avaliações clínicas .....	33
2.4 Métodos de avaliação das tarefas motoras .....	35
2.4.1 Método subjetivo .....	35
2.4.2 Método objetivo .....	36
2.5 Aprendizagem de Máquina .....	38
2.6 Algoritmos de Classificação .....	39
2.6.1 Máquina Vetor Suporte (SVM) .....	40
2.6.2 K-vizinho mais próximo (KNN).....	41
2.6.3 Floresta Aleatória (RF).....	42
2.6.4 Naive Bayes (NB).....	42
<b>CAPÍTULO 3 - MATERIAIS E MÉTODOS.....</b>	<b>44</b>
3.1 Introdução .....	44
3.2 Coleta de dados .....	45
3.2.1 Local da Coleta e População Recrutada .....	45

3.2.2 Dispositivos utilizados na coleta dos dados.....	47
3.2.3 Protocolo experimental para coleta dos dados .....	48
3.3 Processamento dos sinais.....	50
3.4 Extração das características dos sinais .....	51
3.5 Classificadores .....	56
3.6 Peso das características .....	56
3.7 Medidas de Desempenho.....	58
3.8 Divisão dos Dados .....	59
<b>CAPÍTULO 4 - RESULTADOS .....</b>	<b>60</b>
4.1 Resultados encontrados .....	60
<b>CAPÍTULO 5 - DISCUSSÃO.....</b>	<b>72</b>
<b>CAPÍTULO 6 - CONCLUSÃO.....</b>	<b>80</b>
<b>CAPÍTULO 7 - REFERÊNCIAS .....</b>	<b>82</b>

# PREFÁCIO

A tese é composta por 6 capítulos.

O capítulo 1 detalha a justificativa deste trabalho, contando com a motivação, a relevância da tese, o objetivo geral e os específicos e a hipótese deste trabalho. Também foi abordado nesse capítulo as publicações realizadas pela autora ao longo do período acadêmico.

O capítulo 2 aborda os temas necessários para entendimento do trabalho, sendo primeiro tratado sobre o envelhecimento, tarefas motoras, métodos de avaliação das tarefas motoras utilizadas nas avaliações clínicas, incluindo o método subjetivo e o objetivo e, por fim, aprendizagem de máquina com foco nos classificadores, sobretudo SVM, KNN, RF e NB.

O capítulo 3 apresenta a metodologia utilizada, incluindo a coleta de dados, o processamento do sinal, a extração das características, os classificadores utilizados, as medidas de desempenho calculada para cada classificador e a divisão dos dados.

Os resultados foram descritos no capítulo 4.

O capítulo 5 traz a discussão dos achados deste estudo.

O capítulo 6 aborda a conclusão desta tese.

As páginas subsequentes apresentam as referências bibliográficas utilizadas para escrita desta tese.

O volume desta tese de doutorado é de 93 páginas, contando com 24 figuras e 10 tabelas.

# Capítulo 1

## INTRODUÇÃO

---

---

*Este capítulo foi dedicado a contextualizar o problema proposto, abordando a motivação para a realização desta pesquisa, a relevância desta tese, o objetivo geral e específicos do trabalho, além da hipótese e as produções realizadas durante o período do doutorado.*

### 1.1 Motivação

O envelhecimento populacional é realidade desde as últimas décadas em diversos países (BLOOM e LUCA, 2016). Trata-se de uma mudança na estrutura etária da sociedade, onde há um aumento da quantidade de idosos e uma queda no número de crianças e jovens (CARVALHO e GARCIA, 2003).

O envelhecimento humano é um processo multifatorial com variantes intrínsecas (predisposição genética a doenças, por exemplo), e a fatores extrínsecos (hábitos e estilos de vida e condições ambientais, tais como poluição do ar), que modulam a qualidade da experiência de viver dos humanos (DUIM e colab., 2015).

Proporcionalmente ao aumento da população idosa em todo o mundo, há também um crescimento de doenças crônicas não transmissíveis, comorbidades e doenças que acometem o sistema motor do indivíduo (DUIM e colab., 2015). Assim, surgem preocupações e responsabilidades quanto à intensificação da procura de um diagnóstico precoce e confiável dessas doenças, além da predição de distúrbios que podem comprometer a qualidade de vida desses indivíduos.

A identificação de características que auxiliam na avaliação de processos relacionados ao envelhecimento é um assunto cada vez mais estudado. O uso de biomarcadores ajuda a elucidar o processo de envelhecimento, podendo predizer fenótipos relacionados à idade ou

desfecho de saúde, incluindo morbidade, mortalidade, qualidade de vida e tempo vivido com qualidade (VERVOORT e colab., 2016).

Devido ao declínio motor envolvido no processo de envelhecimento humano (AMARAL e colab., 2014; PAPEGAAIJ e colab., 2014; WHO, 2015) há um crescente interesse em avaliar a mobilidade desses indivíduos.

Estudos relatam que a mão é a parte mais ativa dos membros superiores e, devido a sua maior capacidade de movimentação durante as atividades do dia a dia, pode acarretar em diversas alterações fisiológicas e anatômicas e, conseqüentemente, uma maior degradação de funcionamento relacionado à idade (CARMELI e colab., 2003; KALISCH e colab., 2006).

Assim, há a necessidade de analisar possíveis alterações motoras das mãos relacionadas à idade, de modo a verificar em qual etapa da vida começam a surgir essas alterações, e a partir de qual idade o declínio do desempenho motor começa a interferir qualitativamente na vida do indivíduo.

Por meio da execução de tarefas motoras, como supinação/pronação e movimento de pinça, os profissionais da saúde observam a regularidade e destreza do movimento, tal como: amplitude, velocidade, ritmo, alcance, frequência, duração, taxa de toques, dentre outras. Os parâmetros utilizados possibilitam examinar o desenvolvimento neuromotor do indivíduo, auxiliando na detecção de distúrbios de movimento, como a disfuncionalidade e/ou dificuldade para a realização de um movimento ou tarefa motora (KANEKO e colab., 2012). Entretanto, trata-se de uma avaliação observacional, sendo de caráter subjetivo e dependente da *expertise* do profissional da saúde para diagnóstico clínico (FARIA, 2017; FERRI, 2017; WERNER e colab., 2019).

Em vista disso, surge a necessidade da utilização de métodos objetivos que possibilitam caracterizar quantitativamente o movimento, tornando-se ferramentas promissoras para esclarecer o processo de envelhecimento humano, podendo predizer fenótipos relacionados à idade, diagnósticos de diversas patologias ou auxiliar no diagnóstico de disfunções motoras (PEREIRA, 2018).

Atualmente, os sensores inerciais têm-se destacado entre os métodos objetivos devido ao seu tamanho miniaturizado, permitindo sua fixação em diferentes partes do corpo humano, além do seu baixo custo (TESKEY e colab., 2012). Estudos têm utilizado sensores inerciais para quantificar tarefas motoras em seres humanos (KANEKO e colab., 2012), além de investigar alterações devido ao processo de envelhecimento (KALISCH e colab., 2006).

A partir de informações de sinais biomédicos extraídos por sensores inerciais, um método poderoso disponível para investigar e prever as alterações motoras relacionadas à

idade é o uso do *Machine Learning* (ML) (GOECKS e colab., 2020). Dentre as técnicas de aprendizagem de máquina destacam-se os classificadores, que distinguem uma entrada desconhecida com base nos parâmetros de treinamentos anteriores (GOECKS e colab., 2020; HANDELMAN e colab., 2018; RASHIDI e colab., 2019).

Diante da dificuldade em escolher um único classificador, pesquisadores têm optado por usar vários algoritmos de classificação e avaliar qual possui a melhor performance e em quais condições esta foi obtida (BOUROUHOU e colab., 2016). Estudos têm demonstrado que os classificadores KNN, RF, NB e SVM são bastante utilizados para prever eventos relacionadas à idade (ALIZADEH e colab., 2021; BEGG e colab., 2005; CUAYA-SIMBRO e colab., 2021; FUJIO e TAKEUCHI, 2021; FUKUCHI e colab., 2011; MANNINI e colab., 2016; TAREKEGN e colab., 2020; TAVAKOLAN e colab., 2011; WU e WANG, 2008).

Diante deste cenário, este estudo tem como propósito analisar quantitativamente os movimentos manuais de diferentes grupos de indivíduos saudáveis (adultos e idosos), classificar os grupos a partir de diferentes classificadores, calculando qual classificador obteve melhor performance e, avaliar o peso de cada parâmetro utilizado na classificação dos dados.

## 1.2 Relevância da Tese

A complexidade sobre o processo de envelhecimento humano e as consequências em relação as alterações biológicas ocasionadas pelo avanço da idade além de pesaroso para qualquer indivíduo, deve receber a devida atenção pelo poder público. A quantidade de idosos vem aumentando gradativamente, com uma projeção de até 2 bilhões de idosos em todo o mundo e 70 milhões de idosos no Brasil até 2050 (BLOOM e LUCA, 2016). Diante desse cenário, a tomada de decisões dos profissionais da saúde deve ter um maior embasamento, contando com ferramentas fidedignas para que o diagnóstico seja preciso e precoce e, conseqüentemente, o tratamento seja eficaz, aumentando assim a qualidade de vida desses indivíduos.

A utilização de ferramentas precisas e objetivas possibilitam complementar as ferramentas subjetivas já utilizadas por parte dos profissionais da saúde, dando maior respaldo as tomadas de decisões. A partir do conjunto de ferramentas que fornecem medidas

qualitativas e quantitativas, as alterações ocasionadas diante do avanço da idade são melhores esclarecidas.

A abordagem utilizada nesta tese selecionou diferentes algoritmos de classificação para detectar qual o melhor modelo para discriminação dos grupos adultos e idosos saudáveis. Além disso, a utilização de uma ampla variedade de parâmetros (três tarefas distintas, sensores inerciais posicionados em diferentes partes do membro superior dominante, diversas características extraídas pelos sensores inerciais) e, a inclusão dessas características de forma gradual para alimentar os classificadores, foi extremamente relevante para os achados deste estudo, sendo possível verificar quais parâmetros tiveram maior peso na classificação, proporcionando entender melhor as alterações ocorridas devido ao avanço da idade.

Assim, este estudo possui contribuição na área clínica, uma vez que o uso de técnicas objetivas que possibilita avaliar quantitativamente o movimento, combinado com algoritmos de *machine learning* que investiga, prevê e detecta precocemente as alterações motoras devido ao avanço da idade, pode oferecer uma vida mais longa, saudável e independente aos indivíduos idosos, além de ser uma ferramenta de apoio para tomada de decisões.

## 1.3 Objetivos da Pesquisa

### 1.3.1 Geral

Avaliar o desempenho de diferentes classificadores na discriminação de indivíduos adultos e idosos saudáveis a partir da caracterização da função manual, utilizando sensores inerciais.

### 1.3.2 Específicos

Os objetivos específicos deste estudo são:

- (i) Pré-processar os sinais coletados;
- (ii) Extrair características dos sinais;
- (iii) Discriminar os grupos (adultos e idosos) utilizando diferentes classificadores;
- (iv) Calcular a performance de cada classificador;

- (v) Avaliar qual classificador obteve melhor performance;
- (vi) Identificar quais parâmetros, incluindo tarefas, localização dos sensores inerciais, sensor e características, melhor contribuíram para o processo de classificação dos dados;
- (vii) Analisar o peso de cada parâmetro na discriminação dos grupos;
- (viii) Comparar os resultados encontrados com os resultados da literatura;
- (ix) Traçar conclusões baseadas nos resultados encontrados.

## 1.4 Hipótese

O alto desempenho dos algoritmos de classificação da *machine learning* na discriminação de grupos adultos e idosos saudáveis, fornece informações valiosas para avaliações clínicas a partir da previsão de alterações motoras relacionadas ao avanço da idade, diante da caracterização de tarefas motoras e da identificação de características que teve maior peso na classificação dos dados.

## 1.5 Produções realizadas durante o período de Doutorado

### 1.5.1 Produções publicadas em anais de congressos

BARRETO, C.G. Lima; **LELIS SILVA, G.**; Pereira, A.A.; ANDRADE, A.O.; MILAGRE, S.T.. AVALIAÇÃO DE TECNOLOGIAS EM SAÚDE: UMA VISÃO GERAL.. In: Anais do V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica. Anais...Uberlândia (MG) Center Convention Uberlândia, 2018. Disponível em: <<https://www.even3.com.br/anais/cobecseb/78882-AVALIACAO-DE-TECNOLOGIAS-EM-SAUDE--UMA-VISAO-GERAL>>.

**LELIS SILVA, G.**; Adriano Alves Pereira ; MILAGRE, S. T. . Avaliação da usabilidade de tomógrafos de um Estabelecimento Assistencial de Saúde público. In: XII SIMPÓSIO DE ENGENHARIA BIOMÉDICA - IX SIMPÓSIO DE INSTRUMENTAÇÃO E IMAGENS MÉDICAS, 2019, Uberlândia. ANAIS DO XII SIMPÓSIO DE ENGENHARIA BIOMÉDICA - IX SIMPÓSIO DE INSTRUMENTAÇÃO E IMAGENS MÉDICAS, 2019.

REIS NOBREGA, Ligia ; **LELIS SILVA, G.** ; ANDRADE, A. O. ; Adriano Alves Pereira . Uma revisão na literatura sobre o congelamento da marcha em pacientes com Doença de Parkinson. In: XII SIMPÓSIO DE ENGENHARIA BIOMÉDICA - IX SIMPÓSIO DE INSTRUMENTAÇÃO E IMAGENS MÉDICAS, 2019, Uberlândia. ANAIS DO XII SIMPÓSIO DE ENGENHARIA BIOMÉDICA - IX SIMPÓSIO DE INSTRUMENTAÇÃO E IMAGENS MÉDICAS, 2019.

**LELIS SILVA, G.;** LIMA BARRETO, C.G. ; ANDRADE, A. O. ; Adriano Alves Pereira . Marcha Festinada em Pacientes com Doença de Parkinson: Revisão Narrativa. 2020. (Apresentação de Trabalho/Congresso).

### 1.5.2 Produções publicadas em anais de periódicos

1. DE OLIVEIRA ANDRADE, ADRIANO ; SOARES, ADEILSON BARBOSA ; DE ANDRADE PALIS, ANGÉLICA ; CABRAL, ARIANA MOURA ; BARRETO, CASSIANA GABRIELA LIMA ; DE SOUZA, DANIEL BALDOINO ; DE PAULA SILVA, FERNANDA ; SANTOS, FERNANDO PASQUINI ; **SILVA, GABRIELLA LELIS** ; GUIMARÃES, JOSÉ FLÁVIO VIANA ; DE ARAÚJO, LAUREANE ALMEIDA SANTIAGO ; NÓBREGA, LÍGIA REIS ; MENDES, LUANNE CARDOSO ; LUIZ, LUIZA MAIRE DAVID ; BRANDÃO, MARIANA RIBEIRO ; MILAGRE, SELMA TEREZINHA ; DE LIMA GONÇALVES, VERÔNICA ; DE FREITAS MORALES, VICTOR HUGO ; DA CONCEIÇÃO LIMA, VIVIANE ; PEREIRA, ADRIANO ALVES . On the use of telemedicine in the context of COVID-19: legal aspects and a systematic review of technology. RESEARCH ON BIOMEDICAL ENGINEERING, v. 19, p. PMC7954684, 2021.

2. PEREIRA, ADRIANO ALVES ; DE OLIVEIRA ANDRADE, ADRIANO ; DE ANDRADE PALIS, ANGÉLICA ; CABRAL, ARIANA MOURA ; BARRETO, CASSIANA GABRIELA LIMA ; DE SOUZA, DANIEL BALDOINO ; DE PAULA SILVA, FERNANDA ; SANTOS, FERNANDO PASQUINI ; **SILVA, GABRIELLA LELIS** ; GUIMARÃES, JOSÉ FLÁVIO VIANA ; DE ARAÚJO, LAUREANE ALMEIDA SANTIAGO ; NÓBREGA, LÍGIA REIS ; MENDES, LUANNE CARDOSO ; BRANDÃO, MARIANA RIBEIRO ; MILAGRE, SELMA TEREZINHA ; DE LIMA GONÇALVES, VERÔNICA ; DE FREITAS MORALES, VICTOR HUGO ; DA CONCEIÇÃO LIMA, VIVIANE . Non-pharmacological treatments for COVID-19: current status and consensus. RESEARCH ON BIOMEDICAL ENGINEERING, v. 16, p. PMC7809889, 2021.

3. MILAGRE, SELMA TEREZINHA ; PEREIRA, ADRIANO ALVES ; DE OLIVEIRA ANDRADE, ADRIANO ; DE ANDRADE PALIS, ANGÉLICA ; CABRAL, ARIANA MOURA ; BARRETO, CASSIANA GABRIELA LIMA ; DE SOUZA, DANIEL BALDOINO ; DE PAULA SILVA, FERNANDA ; SANTOS, FERNANDO PASQUINI ; **SILVA, GABRIELLA LELIS** ; GUIMARÃES, JOSÉ FLÁVIO VIANA ; DE ARAÚJO, LAUREANE ALMEIDA SANTIAGO ; NÓBREGA, LÍGIA REIS ; MENDES, LUANNE CARDOSO ; BRANDÃO, MARIANA RIBEIRO ; DE LIMA GONÇALVES, VERÔNICA ; DE FREITAS MORALES, VICTOR HUGO ; DA CONCEIÇÃO LIMA, VIVIANE . Effectiveness and quality analysis of methods in studies for the treatment of COVID-19. RESEARCH ON BIOMEDICAL ENGINEERING, v. 13, p. PMC7969148, 2021.

4. **Silva, G.L.**, Zaruz, M.J.F., Milagre, S.T. *et al.* Assessment of the performance of classifiers in the discrimination of healthy adults and elderly individuals through functional fitness tasks. Res Biomed. Eng. **39**, 245-258 (2023). <https://doi.org/10.1007/s42600-023-00271-1>.

### 1.5.3 Trabalhos técnicos realizados

1. Adriano Alves Pereira ; ANDRADE, A. O. ; CABRAL, A. M. ; LIMA BARRETO, C.G. ; **LELIS SILVA, G.** ; GUIMARAES, J. F. V. ; ARAUJO, L. A. S. ; REIS NOBREGA, Ligia ; MENDES, L. C. ; BRANDAO, M. R. ; MILAGRE, S. T. ; MORALES, V. H. F. ; LIMA, V. C. . Custo estimado para atendimento assistencial à saúde de 100 leitos de UTI de Campanha, considerando infraestrutura física, recursos materiais operacionais e oferta de gases medicinais. 2020.

2. MILAGRE, S. T. ; Adriano Alves Pereira ; ANDRADE, A. O. ; LIMA BARRETO, C.G. ; **LELIS SILVA, G.**. Avaliação de máscaras cirúrgicas da empresa A.R.S. BRASIL INDÚSTRIA E COMÉRCIO, DISTRIBUIÇÃO DE ROUPAS E BRINDES EIRELI (CNPJ: 24.795.369/0001-04) recebidas pelo Hospital de Clínicas de Uberlândia da Universidade Federal de Uberlândia (HCU-UFU). 2020.

3. Adriano Alves Pereira ; ANDRADE, A. O. ; CABRAL, A. M. ; LIMA BARRETO, C.G. ; SOUZA, D. B. ; **LELIS SILVA, G.** ; GUIMARAES, J. F. V. ; ARAUJO, L. A. S. ; REIS NOBREGA, Ligia ; MENDES, L. C. ; BRANDAO, M. R. ; MILAGRE, S. T. ; GONCALVES, V. L. ; MORALES, V. H. F. ; LIMA, V. C. . Nota Técnica COVID-19: DIAGNÓSTICO, TRATAMENTO E INTERVENÇÃO FARMACOLÓGICA. 2020.

# Capítulo 2

## FUNDAMENTAÇÃO TEÓRICA

---

*O objetivo deste capítulo é apresentar os fundamentos teóricos necessários para entendimento do assunto abordado.*

### 2.1 Envelhecimento Populacional

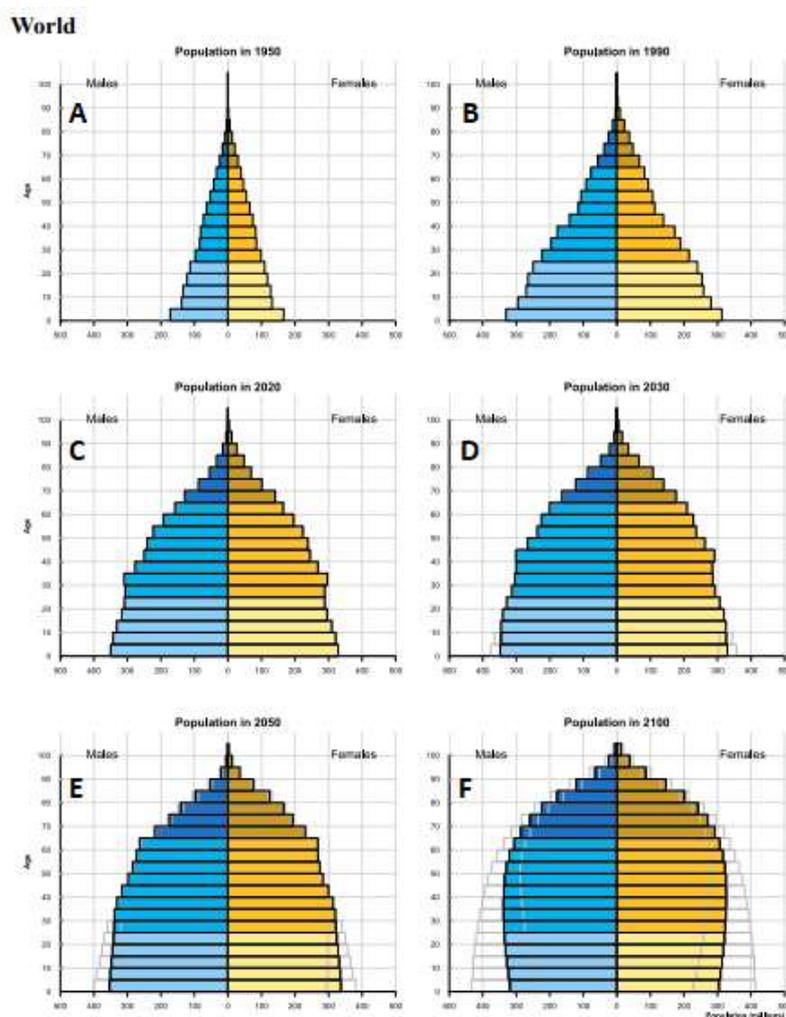
O aumento da expectativa de vida tem sido um assunto amplamente discutido, que vêm acontecendo de forma acelerada e a nível mundial. Trata-se de um fenômeno dominante do século XXI, que ocorreu primeiramente em países desenvolvidos e, recentemente, também tem sido observado nos países em desenvolvimento (BLOOM e LUCA, 2016).

Segundo a Organização Mundial de Saúde (OMS), idoso é todo indivíduo com idade igual ou superior a 60 anos, porém, quanto à formulação de políticas públicas, esse limite pode variar segundo as condições de cada país (WHO, 2015).

O envelhecimento populacional é comumente definido como um aumento da proporção de indivíduos com idade acima de 60 anos em relação à população total (MARTIN, 2011). Assim, o envelhecimento populacional está relacionado com a mudança na estrutura etária de uma sociedade (CARVALHO e GARCIA, 2003).

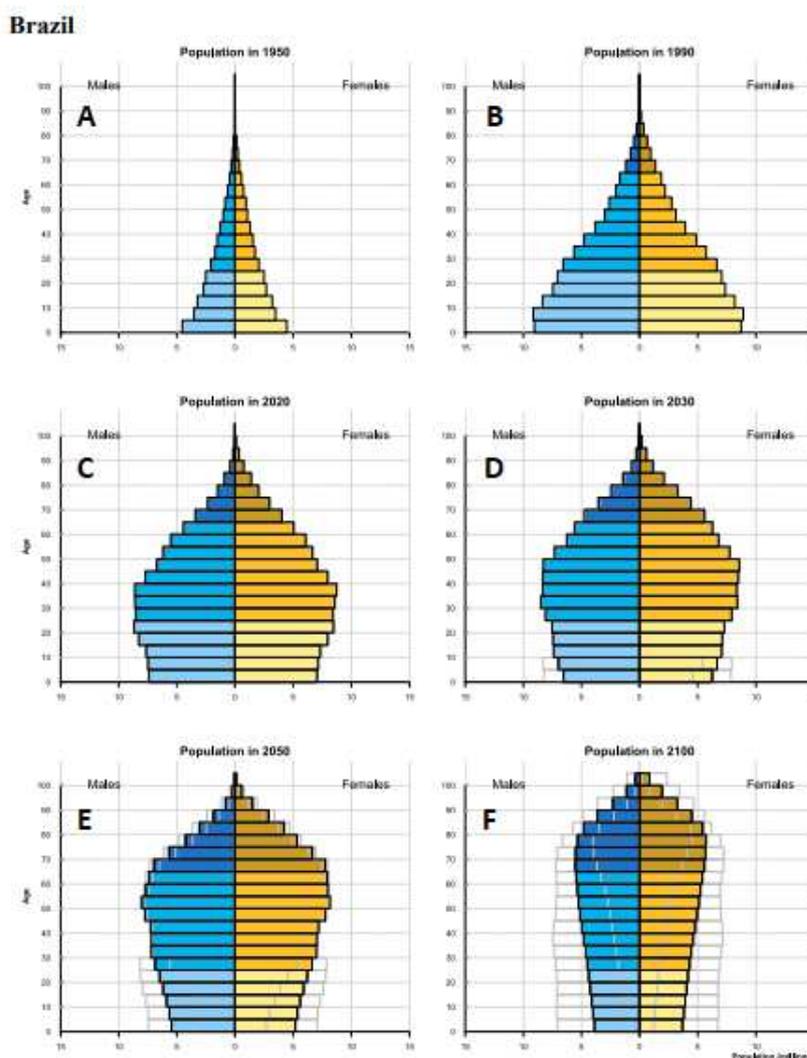
A composição etária de um país é quantificada pela proporção de crianças, jovens, adultos e idosos, sendo uma ferramenta importante para governantes no âmbito de políticas públicas econômicas e de saúde. O envelhecimento populacional refere-se à uma redução da quantidade de crianças e jovens, percebido juntamente com o aumento da quantidade de idosos em uma população (WHO, 2015).

À medida que há um envelhecimento populacional, a pirâmide etária de uma sociedade se altera. Se antes a estrutura piramidal do mundo configurava uma pirâmide triangular, nos próximos anos teremos uma estrutura mais cilíndrica, onde haverá uma distribuição mais regular entre as faixas etárias, conforme Figuras 2.1 e 2.2.



**Figura 2.1 - Pirâmide etária do Mundo. As barras coloridas indicam os dados de variantes médias, o sombreamento em cinza (mostrados nas figuras D, E e F) indica a incerteza, com intervalo de precisão de 95%. (A) População mundial em 1950. (B) População mundial em 1990. (C) População mundial em 2020. (D) Projeção da população mundial em 2030. (E) Projeção da população mundial em 2050. (F) Projeção da população mundial em 2100**

**FONTE: (NATIONS, 2019)**



**Figura 2.2 - Pirâmide etária do Brasil. As barras coloridas indicam os dados de variantes médias, o sombreado em cinza (mostrados nas figuras D, E e F) indica a incerteza, com intervalo de precisão de 95%. (A) População brasileira em 1950. (B) População brasileira em 1990. (C) População brasileira em 2020. (D) Projeção da população brasileira em 2030. (E) Projeção da população brasileira em 2050. (F) Projeção da população brasileira em 2100**

**FONTE: (NATIONS, 2019)**

Segundo *Bloom e Luca* (2016), em 2050 a maior parcela populacional mundial será constituída por indivíduos com idade superior a 60 anos, com projeção de até 2 bilhões de idosos em todo o mundo e, no Brasil este número poderá chegar a 70 milhões, triplicando os números observados no ano de 2010.

Essa transição demográfica percebida no Brasil e no mundo é resultado da diminuição das taxas de natalidade e mortalidade populacionais (BLOOM e LUCA, 2016; MARTIN, 2011; WHO, 2015).

Observado em todo o mundo, principalmente nos países desenvolvidos, a quantidade de filhos por família tem caído substancialmente. Além disso, os avanços agrícolas e de higiene, e a descoberta de antibióticos pós Segunda Guerra Mundial contribuíram para a diminuição da taxa de mortalidade e, conseqüentemente, no aumento da longevidade da população (MACIA e colab., 2019).

Ainda, a incorporação de novas tecnologias em saúde está associada ao processo de transição demográfica, uma vez que devido ao rápido avanço tecnológico, incluindo desde o diagnóstico precoce de doenças até melhores tratamentos oferecidos à população, proporciona uma melhora da qualidade de vida dos indivíduos e, conseqüentemente, na queda da mortalidade em geral (AMORIM e colab., 2011).

Embora a idade cronológica não seja um marcador preciso para as mudanças que acompanham o envelhecimento, uma vez que existem variações no estado de saúde e independência entre idosos da mesma idade, há a necessidade de formular medidas de apoio que garantem à essa população uma vida mais digna (WHO, 2015).

Diante dos fatos destacados, houve a necessidade de mudanças nas políticas públicas sociais e de saúde frente ao envelhecimento populacional, sendo um dos maiores desafios nos próximos anos. Assim, com o aumento da população idosa é extremamente importante entender as características biológicas do envelhecimento humano, além de criar meios para quantificar e investigar essas alterações, de forma a oferecer uma melhora da qualidade de vida desses indivíduos e um maior embasamento aos profissionais da saúde nas rotinas de avaliações clínicas.

## **2.2 Características biológicas do envelhecimento humano**

O envelhecimento humano é um dos desafios mais proeminentes dos últimos anos, sendo de extrema importância uma melhor compreensão sobre esse processo. O desafio é compreender melhor as alterações biológicas que ocorrem devido à idade e suas principais conseqüências.

Trata-se de um processo dinâmico e progressivo, o qual o organismo sofre alterações morfológicas, funcionais, bioquímicas e psicológicas. Essas alterações são determinantes para uma perda progressiva da capacidade de adaptação ao meio ambiente, podendo aumentar a

vulnerabilidade e incidências de patologias que podem levar à morte do indivíduo (CARVALHO FILHO e PAPALÉO NETTO, 2005).

Embora os declínios de funções cognitivas e motoras estejam intimamente ligados ao processo de envelhecimento humano, grande parte dos problemas enfrentados pelos idosos estão relacionados com a perda e ou diminuição da visão, audição e movimentos (WHO, 2015), entretanto, ainda há incertezas quanto às causas desses prejuízos durante o envelhecimento (FROLOV e colab., 2020; LACREUSE e colab., 2006; OLIVEIRA e colab., 2018).

Quando há comprometimento do sistema motor devido ao processo de envelhecimento, observa-se uma mudança a nível comportamental (PAPEGAAIJ e colab., 2014).

Com a redução da atividade diária associado a possíveis déficits das funções motoras e cognitivas em idosos, há uma perda de avanços dominantes dos membros superiores e inferiores, podendo provocar alterações no sistema motor (AMARAL e colab., 2014).

Dentre as principais mudanças motoras relacionadas ao envelhecimento, destaca-se o aumento do tempo de reação, o que explica grande parte de quedas em idosos (OLIVEIRA e colab., 2018), redução do controle motor, baixa capacidade de coordenação e execução de movimentos, dificuldade no aprendizado de novas tarefas (FROLOV e colab., 2020), variabilidade crescente da produção motora e desaceleração do movimento (QUANDT e colab., 2016).

Enquanto as alterações estruturais do cérebro do idoso estão relacionadas com a degeneração da matéria cinzenta e branca (córtex cerebral) e dos nervos periféricos, as alterações funcionais dessas estruturas cerebrais estão associadas as modificações em que operam uma tarefa motora. Se por um lado essas modificações podem ser de maneira negativa, onde há uma deterioração funcional, por outro, pode haver compensações funcionais. Assim, o desempenho da tarefa motora pode ser medido pela restauração da função por meio da compensação (PAPEGAAIJ e colab., 2014).

Estudos têm mostrado que a ativação cerebral nos idosos ocorre de forma mais forte e ou com ativação de regiões adicionais durante a execução de tarefas motoras, quando comparado à indivíduos mais jovens (BERCHICCI e colab., 2012; FERNANDEZ-RUIZ e colab., 2018).

O estudo de *Heuninckx e colaboradores* (2008) analisou se a super ativação nas redes motoras dos idosos é resultado da compensação ou devido a desdiferenciação a nível cerebral. Como resultado, os autores encontraram que a coordenação durante o movimento foi

resultado de ativação de regiões motoras clássicas, sensoriomotoras e regiões frontais em idosos, consistente com a hipótese de compensação, caracterizando a neuroplasticidade no nível de sistemas no cérebro envelhecido.

Outro sintoma associado ao processo de envelhecimento natural é o aumento da amplitude do tremor fisiológico, afetando diretamente a qualidade de vida dos idosos, devido às limitações físicas, funcionais, sociais e manutenção de cuidados pessoais (MORRISON e NEWELL, 2012).

Tremor é um sintoma presente em todos os indivíduos e pode ocorrer em repouso (tremor de repouso) ou durante a manutenção postural do membro (tremor postural). O tremor é definido como uma oscilação de forma involuntária e rítmica em diferentes partes do corpo humano (DEUSCHL, 1999; STURMAN e colab., 2005), sendo bastante comum nos membros superiores (MORRISON e NEWELL, 2012). O tremor pode ser fisiológico, causado por propriedades mecânicas do músculo, uma vez que ocorre durante a ativação dos músculos (DEUSCHL, 1999) ou sob condições de estresse, ansiedade, fadiga muscular ou uso de alguns medicamentos (BHIDAYASIRI, 2005), ou ainda patológico, sintoma comum em distúrbios de movimento, como na Doença de Parkinson (DP) (STURMAN e colab., 2005).

Em indivíduos saudáveis, o tremor fisiológico é caracterizado como sendo um tremor postural, de baixa amplitude e frequência em torno de 8 a 12 Hz (MORRISON e NEWELL, 2012; STURMAN e colab., 2005). Em indivíduos idosos, o aumento da frequência do tremor ocorre devido principalmente ao declínio da capacidade funcional do sistema neuromuscular (MORRISON e NEWELL, 2012).

O estudo de *Morrison e colaboradores* (2006) detectou um aumento da amplitude do tremor de mão e dedo em indivíduos idosos, entretanto, diante de uma abordagem experimental utilizando o membro superior sem nenhum apoio e com o indivíduo na posição vertical (em pé), o aumento do tremor foi maior. No estudo realizado por *Sturman e colaboradores* (2005) não houve diferença na amplitude do tremor do membro superior entre o grupo de jovens e idosos quando medidas sob a condição de repouso, porém, quando o membro superior estava contra a força da gravidade (tremor postural), foi observada diferença significativa entre os grupos de jovens e idosos.

Assim, o protocolo que utiliza a abordagem experimental em que o membro superior se encontra sem nenhum apoio, fornece avaliações mais realistas das respostas do tremor, onde os ajustes posturais podem influenciar a dinâmica do tremor, dado que essas tarefas aumentam as demandas de controle do sistema neuromotor (MORRISON e NEWELL, 2012).

Diante do exposto, o processo de envelhecimento humano está intimamente relacionado com os impactos desenvolvidos a partir de doenças e ou alterações biológicas, que contribuem com a perda de funcionalidade e autonomia. Como consequência, as tarefas são realizadas de forma mais lentas e menos precisas, quando comparadas às outras faixas etárias. Além disso, a redução dos movimentos e da força articular nos idosos aumentam os riscos de distúrbios biomecânicos e de lesões osteoarticulares, que podem ser frequentes e cumulativos, assim como de quedas (AMARAL et al., 2014).

As alterações biológicas ocorridas devido ao processo de envelhecimento possuem efeitos devastadores para os idosos, onde há uma piora do estado geral desses indivíduos, levando-os ao isolamento, aumento do risco de quedas e fraturas, além de um prejuízo das atividades de vida diária (AVDs) (AMARAL e colab., 2014; FROLOV e colab., 2020). Além das consequências na vida desses indivíduos, esses desfechos em saúde trazem consequências também para os sistemas de saúde, devido ao aumento da demanda por assistência médica (MEIER e colab., 2012; TAREKEGN e colab., 2020).

Além das alterações biológicas aqui mencionadas, serão abordadas em um tópico separado as alterações manuais que ocorrem devido ao avanço da idade, uma vez que o objetivo do trabalho é a classificação de grupos adultos e idosos saudáveis, a partir da caracterização da função manual.

### **2.2.1 Alterações manuais devido ao avanço da idade**

Os membros superiores são a parte mais ativa do sistema motor humano, sobretudo as mãos e, diante do alto grau de utilização para a realização dos movimentos do dia a dia, possuem uma maior degradação de suas funções devido ao processo de envelhecimento (CARMELI e colab., 2003; KALISCH e colab., 2006).

Ao longo da vida, as mãos passam por diversas mudanças, sendo elas anatômicas ou fisiológicas. Devido ao avanço da idade, pode haver uma perda degenerativa da massa muscular esquelética, chamado de sarcopenia, resultando no declínio tanto da força manual quanto da resistência. Além disso, as alterações da função manual também podem ser resultado das alterações ocorridas no sistema nervoso periférico dos idosos, como diminuição da velocidade de condução nervosa e percepção sensorial (SKRZEK e colab., 2015).

Segundo a revisão realizada por *Carmeli e colaboradores*. (2003), as principais alterações que causam declínios na função das mãos estão relacionadas à força, velocidade de movimento e sentido de vibração. *Skrzek e colaboradores* (2015) destaca que as mudanças à

nível cerebral e sistema nervoso central (SNC) afeta a capacidade de repetição de movimentos em alta frequência, além de perdas de habilidades motoras e atividade motora lenta. Corroborando com os achados, o estudo experimental de *Ranganathan e colaboradores*. (2001) quantificou as alterações funcionais das mãos de indivíduos idosos, comprovando um efeito degenerativo na função da mão e dos dedos, sobretudo, na força (com maior severidade em mulheres) e velocidade dos movimentos e na capacidade de manter a força durante o movimento de pinça. *Smith e colaboradores*. (1999) demonstraram que a habilidade motora fina se deteriora com o avanço da idade, indicando uma idade crítica (60 anos) no declínio do desempenho manual ou piora abrupta.

As alterações ocorridas devido ao avanço da idade, indicando uma deterioração das habilidades motoras finas, pode estar relacionado à perda da massa muscular, afetando a coordenação e, conseqüentemente, a precisão dos movimentos (SKRZEK e colab., 2015). Por volta dos 65 anos de idade a função da mão começa a se degradar lentamente, após os 75 torna-se mais fácil a visualização dessas disfunções, percebidos no padrão de prensão, força, tempo de desempenho e amplitude de movimento e, até os 90 anos de idade, é esperado uma redução em torno de 40% da amplitude de movimento das mãos de idosos quando comparados à indivíduos com idade igual a 30 anos (CARMELI e colab., 2003).

Perante as alterações biológicas ocorridas devido ao processo de envelhecimento humano (AMARAL e colab., 2014; BERCHICCI e colab., 2012; CARMELI e colab., 2003; FERNANDEZ-RUIZ e colab., 2018; FROLOV e colab., 2020; KALISCH e colab., 2006; LACREUSE e colab., 2006; OLIVEIRA e colab., 2018; PAPEGAAIJ e colab., 2014; RANGANATHAN e colab., 2001; SKRZEK e colab., 2015; SMITH e colab., 1999), há uma necessidade de complementar os métodos de diagnósticos ou prevenção dessas patologias a partir da combinação de duas técnicas, a análise qualitativa e a quantitativa.

Um método bastante utilizado e valioso nas rotinas clínicas é a utilização de tarefas motoras, as quais ajudam a detectar, acompanhar ou prevenir certas patologias (DAI e colab., 2015).

### 2.3 Tarefas motoras e suas utilizações nas avaliações clínicas

As tarefas motoras são comumente definidas como uma sequência organizada e bem coordenada de movimentos voluntários do tronco, cabeça e membros, com intuito de realizar um movimento. Para que o movimento humano seja bem executado, o sistema motor responde a uma série de reações em cascata até chegar ao músculo (VOELCKER-REHAGE, 2008).

As habilidades motoras compreendem a maior parte do dia a dia de qualquer indivíduo, desempenhando um papel crucial em todas as fases da vida. O desempenho humano é caracterizado pela medição das habilidades motoras (VOELCKER-REHAGE, 2008).

O desenvolvimento motor pode ser classificado em habilidade motora grossa (complexa) e habilidade motora fina (GONZALEZ e colab., 2019).

A habilidade motora grossa está relacionada com o controle postural, envolvendo equilíbrio estático e dinâmico, postura, balanço e deslocamento. Para isto, envolve a participação de grupos de músculos maiores do corpo humano, estimulando a realização de movimentos como andar, sentar-se, pular, etc (GONZALEZ e colab., 2019).

Por outro lado, a coordenação motora fina relaciona-se com movimentos que exigem maior precisão e destreza, onde há a ativação de grupos de músculos menores, como por exemplo, os músculos das mãos e pés, para realização de atividades como segurar um objeto e abrir uma porta (GONZALEZ e colab., 2019).

Os movimentos finos representam grande parte das tarefas comuns realizadas no dia a dia, as quais são produzidas na maior parte do tempo pelas mãos. Para tanto, requer movimentos precisos e coordenados que combinem o uso das mãos, dedos e punhos. Além disso, exige uma comunicação de estruturas do SNC e sistema nervoso periférico para o perfeito movimento, incluindo, desde estruturas do córtex motor até processamento de funções visuoespaciais e sensoriais (BURR e CHOUDHURY, 2021).

Em termos de controle motor, a destreza manual constitui-se de componentes chaves que permitem o movimento da mão e o controle dos dedos de maneira independente em termos de tempo, força e cinemática (TÉRÉMETZ e colab., 2015). A funcionalidade correta da mão e a capacidade de realização de movimentos precisos e coordenados da mão e dos dedos, conhecida como destreza manual, depende da interação de componentes sensoriais e

motores do indivíduo, além da capacidade de realização do movimento de supinação/pronação (SOUBEYRAND e colab., 2017).

A tarefa de supinação e pronação refere-se a um movimento complexo em que o indivíduo gira a palma da mão para cima (supinação) e para baixo (pronação), possibilitando a orientação da mão e, conseqüentemente, na realização de diversos movimentos das atividades diárias (KANEKO e colab., 2012; SOUBEYRAND e colab., 2017). O movimento inicia-se no cotovelo, prolonga-se até o antebraço que, ao se rotacionar, permite direcionar a palma da mão para cima, medial ou para baixo, com estabilizações feitas por meio de ligamentos, músculos e articulações (SOUBEYRAND e colab., 2017; VOLPON, 1996).

Além disso, a capacidade de realizar tarefas utilizando as mãos, imprimir forças e segurar objetos só é possível a partir da força de prensão manual, que dentre os diversos tipos destaca-se o “*Pinch Grip*”, ou prensão de pinça (BORGES JUNIOR e colab., 2011).

A aproximação e a força que o polegar exerce sobre a falange distal de cada um dos dedos permite a realização do movimento de pinça. Este movimento é caracterizado como um movimento de compressão e afastamento entre o polegar com os demais dedos, possibilitando a execução de diversos movimentos do dia a dia (BORGES JUNIOR e colab., 2011).

Estudos têm demonstrado que o avanço da idade possui influência nos movimentos de supinação e pronação (JIMÉNEZ-JIMÉNEZ e colab., 2011; RUIZ e colab., 2007) e no movimento de pinça ou toque dos dedos (AOKI e FUKUOKA, 2010; COUSINS, 1998; JIMÉNEZ-JIMÉNEZ e colab., 2011; NUTT e colab., 2000; RUFF e PARKER, 1993; RUIZ e colab., 2007).

Informações embutidas durante a execução desses movimentos podem ser detectadas através da avaliação da variabilidade, como por exemplo informações que discriminam padrões e diferenças na caracterização entre diferentes grupos de população, detecção precoce da deterioração de parte do sistema biológico e prognóstico em tempo real (BRAVI; LONGTIN; SEELY, 2011).

A não linearidade das habilidades e características do movimento variam ao longo do tempo. Diferentes condições de movimentos geram diferentes padrões durante a execução de uma tarefa e, por isso, o uso de características relacionadas à amplitude, frequência e variabilidade de tarefas motoras tem sido bastante utilizado na detecção de doenças ou idade, por exemplo (HARBOURNE; STERGIOU, 2009; SOUZA; ANDRADE; VIEIRA, 2018).

A execução de alguns movimentos motores pode ser utilizada para detectar a presença ou evolução de algumas doenças, especialmente, aquelas associadas ao envelhecimento. No cenário clínico, uma série de tarefas articulares, tal como: toque dos dedos, supinação e

pronação, flexão e extensão do punho, fornecem uma série de informações que podem ser aplicadas nas rotinas de avaliação e acompanhamentos clínicos (DAI e colab., 2015).

Dentre os diversos métodos para diagnósticos de doenças, especialmente as neurológicas, o movimento de pinça e de supinação e pronação são bastante utilizados. Para tanto, diante da execução de tais tarefas motoras, os profissionais da saúde observam a regularidade e destreza do movimento, tal como: amplitude, velocidade, ritmo, alcance, frequência, duração, taxa de toques, dentre outras. Os parâmetros utilizados possibilitam examinar o desenvolvimento neuromotor do indivíduo, auxiliando na detecção de distúrbios de movimento, como a disfuncionalidade e ou dificuldade para a realização de um movimento ou tarefa motora (KANEKO e colab., 2012).

O declínio do desempenho motor relacionado à idade está bem documentado, incluindo tarefas motoras complexas e finas, na qual há um déficit na coordenação do movimento das mãos, capacidade de controlar a força e executar movimentos sequenciais (FROLOV e colab., 2020; KALISCH e colab., 2006; PAPEGAAIJ e colab., 2014; RANGANATHAN e colab., 2001; SKRZEK e colab., 2015; SMITH e colab., 1999; SOROND e colab., 2015; VOELCKER-REHAGE, 2008). Assim, a avaliação de tarefas motoras frente ao envelhecimento auxilia no esclarecimento do processo contribuindo com a minimização dos efeitos funcionais.

## **2.4 Métodos de avaliação das tarefas motoras**

Existem dois métodos para avaliar e caracterizar tarefas motoras. O método subjetivo utiliza medidas por intermédio de observações e testes, permitindo uma análise qualitativa. Já o método objetivo utiliza medidas por intermédio de dispositivos e ou equipamentos, permitindo uma análise quantitativa (FERRI, 2017).

### **2.4.1 Método subjetivo**

O método subjetivo é uma avaliação observacional do evento que pretende analisar, podendo ser a partir do autorrelato do paciente ou a partir de um profissional que avalia o paciente (FARIA, 2017; FERRI, 2017; WERNER e colab., 2019).

A abordagem a partir do autorrelato do paciente está relacionado à percepção da performance da funcionalidade da biomecânica corporal auto referida. Embora seja um método fácil e rápido, podem apresentar erros devido à percepção que o paciente possui dele mesmo, influenciando o resultado da análise. Já os métodos diretos consistem na participação de um avaliador com experiência, na qual solicita algumas tarefas ao paciente e o avalia de acordo com critérios pré-estabelecidos e padronizados (FERRI, 2017).

A abordagem subjetiva é comum e bastante utilizada por profissionais da área da saúde, para avaliar a qualidade das tarefas motoras executadas, por não necessitar de tecnologias e pelo baixo custo de realização. Entretanto, possui uma confiabilidade moderada, uma vez que é um método subjetivo e que, a nível de patologias neurológicas, há uma maior dificuldade na avaliação dessas tarefas motoras (FERRI, 2017; PEREIRA, 2018; WERNER e colab., 2019).

Embora seja uma avaliação subjetiva, podendo obter diferentes resultados a partir de diferentes pontos de vista, ainda são bastante utilizados para auxiliar no diagnóstico de diversas patologias com distúrbios do movimento.

Atualmente, o diagnóstico de diversas doenças com comprometimento motor carece de um método mais fidedigno (PEREIRA, 2018). Assim, diante da dificuldade vivenciada, torna-se necessário métodos que complementem os métodos subjetivos e auxiliem na detecção dessas disfunções, permitindo diagnósticos precoces e mais confiáveis.

### **2.4.2 Método objetivo**

Os métodos objetivos utilizam meios que fornecem informações quantitativas a respeito do que está se observando, possibilitando compreender os mecanismos de cada tarefa motora, avaliando os prejuízos biomecânicos e, conseqüentemente, fornecendo dados mais confiáveis para o diagnóstico das alterações biomecânicas do indivíduo (FARIA, 2017; FERRI, 2017).

A utilização de dispositivos refere-se a um método mais confiável, porém seus custos são elevados quando comparados aos métodos subjetivos (FARIA, 2017). Dentre as estratégias para detecção de disfunções motoras os sensores inerciais têm obtido bastante ênfase.

Os sensores inerciais têm sido amplamente utilizados na captura de movimentos, por tratar de um sistema prático, simples e de fácil acesso. Além disto, essas unidades de medição inercial (IMU) possuem tamanhos pequenos, possibilitando o desenvolvimento de

dispositivos miniaturizados, fornecendo dados sobre angulação, velocidade, aceleração e posição no espaço. Podem ser resumidos aos acelerômetros, giroscópios e magnetômetros (FERRI, 2017).

Os acelerômetros são dispositivos que medem a vibração ou aceleração estática e dinâmica do movimento de uma estrutura, ou seja, são transdutores capazes de medir a aceleração linear ao longo de um eixo sensível (FERRI, 2017).

Os acelerômetros possuem diversos tipos e a sua escolha deve estar relacionada com o tipo de sistema que se pretende avaliar. Os piezoelétricos são os mais comuns e referem-se a transdutores de energia, transformando energia mecânica em energia elétrica. Os acelerômetros capacitivos medem tanto a aceleração estática quanto a dinâmica, permitindo determinar em que direção e velocidade o sistema está se movendo. Por fim têm-se os acelerômetros triaxiais, que medem a vibração em três eixos ortogonais (X, Y e Z), fornecendo valores de aceleração individualizados, aumentando sua eficiência (FARIA, 2017).

Os giroscópios são sensores que medem a variação da velocidade angular, por meio da medição da força de *Coriolis* exercida na massa vibrante. Quando há uma rotação desse dispositivo, há uma variação da capacitância entre os eletrodos fixos do sistema e os eletrodos da massa suspensa. Por serem menos sensíveis à influência da gravidade, os giroscópios têm sido bastante utilizados para cálculo de parâmetros de algumas tarefas motoras, tais como marcha humana e tremor postural (FERRI, 2017).

Os magnetômetros são sensores responsáveis por converter informações do campo magnético em sinais elétricos. Esses sensores são baseados nos efeitos magnetoresistivos, na qual há uma mudança na resistividade do sensor devido à um campo magnético, sendo que essa mudança é proporcional ao ângulo de inclinação do sensor em relação à direção do campo magnético (FERRI, 2017).

Diante da diversidade de dados que podem ser coletados pelos sensores inerciais e, pela alta capacidade de caracterização de tarefas motoras, esse método de avaliação tem sido associado a outras técnicas, como aprendizagem de máquina, tornando o diagnóstico de patologias associadas aos movimentos humanos mais preciso e fidedigno.

## 2.5 Aprendizagem de Máquina

Aprendizagem de máquina (do inglês *Machine Learning* – ML) tem sido aplicado em diversas áreas, sobretudo, na medicina (GOECKS e colab., 2020; HANDELMAN e colab., 2018). Trata-se de uma subárea da Inteligência Artificial (IA), que utiliza algoritmos que permitem à máquina aprender e classificar padrões de forma segura e rápida (GOECKS e colab., 2020).

Enquanto a IA inclui técnicas que permitem às máquinas imitarem o comportamento humano de forma inteligente, o ML desenvolve algoritmos que permitem aos computadores aprender com experiências passadas para prever um resultado, ou ainda, classificar e agrupar padrões. Os modelos são construídos a partir de um grande número de dados, sendo treinados através de abordagens matemáticas e estatísticas, permitindo a classificação, agrupamento e previsão de novos dados (GOECKS e colab., 2020; HANDELMAN e colab., 2018; RASHIDI e colab., 2019).

Dentre os algoritmos de aprendizagem de máquina mais utilizados destacam-se a (i) aprendizagem supervisionada, que classifica e prevê classes baseados em experiências passadas e, (ii) aprendizagem não supervisionada ou semi supervisionada, que identifica a estrutura, geralmente *clusters*, entre dados não rotulados (GOECKS e colab., 2020).

Os algoritmos utilizados na aprendizagem supervisionada utilizam o treinamento de dados para descrever uma função que associa entrada com saída, ou seja, os métodos distinguem uma entrada desconhecida com base nos parâmetros de treinamentos anteriores. Nessa metodologia, existem duas principais categorias, a classificação da aprendizagem supervisionada, na qual os dados de entrada produzem uma saída discreta (qualitativa), ou a abordagem de regressão, que envolve a aquisição cumulativa de dados para produção numérica contínua (quantitativa) (RASHIDI e colab., 2019).

Assim, os principais focos dos algoritmos de aprendizagem supervisionada são: (i) classificação, que identifica em qual categoria ou grupo uma nova observação (por exemplo, um indivíduo) pertence, utilizando dados de treinamentos compostos por atributos ou características, cuja associação de categoria é conhecida e, (ii) regressão, que prevê valores contínuos para uma nova variável, a partir do treinamento de instâncias com valores conhecidos dessa variável (HANDELMAN e colab., 2018).

Já os algoritmos utilizados na aprendizagem não supervisionada, também conhecidos como algoritmos de *clustering*, envolve o agrupamento de dados não rotulados para produção

de grupos (*clusters*) que possuem semelhanças. Neste caso, o objetivo principal é descobrir padrões relevantes para o estudo e dividi-los em grupos (RASHIDI e colab., 2019).

O agrupamento de dados pode ser definido como a determinação de um conjunto finito de categorias, que descreve uma base de dados de acordo com a similaridades entre seus objetos. Assim, o principal objetivo do agrupamento refere-se à obtenção de informações sobre os dados, como por exemplo, identificação de características e classificação dos dados (CELEBI e colab., 2013). Na maioria dos casos, a base de dados disponível é descrita por meio de atributos (características) dos objetos, de forma que o algoritmo de agrupamento possa atuar tanto por meio dos atributos como por meio da similaridade (ou dissimilaridade) entre os objetos (PETERSON e colab., 2018).

Assim, o *clustering* é realizado calculando a similaridade ou proximidade com base no método de medição de distância (JUNG e colab., 2014).

Devido aos avanços tecnológicos ocorridos nos últimos anos e das técnicas de IA e ML, a medicina tem se revolucionado bastante. Com algoritmos de ML, os quais utilizam análise de grandes conjuntos de dados relacionados a tratamentos e desfechos clínicos, proporcionam o auxílio ao diagnóstico precoce e predição de novos dados, além de individualizar tratamentos e realizar o monitoramento contínuo em apoio à saúde geral, proporcionando melhoria na qualidade de vida (GOECKS e colab., 2020; HANDELMAN e colab., 2018).

O uso de algoritmos de ML pode auxiliar no entendimento do processo de envelhecimento humano, como por exemplo a partir da classificação dos dados por meio de características de indivíduos de diversas faixas etárias.

## 2.6 Algoritmos de Classificação

Dentre as técnicas de aprendizagem de máquina supervisionada destacam-se os classificadores, que distinguem uma entrada desconhecida com base nos parâmetros de treinamentos anteriores, sendo a classificação referente à previsão de dados categóricos (BI e colab., 2019; GOECKS e colab., 2020; HANDELMAN e colab., 2018; RASHIDI e colab., 2019).

De forma geral, os algoritmos de classificação permitem a previsão de saídas (variáveis aleatórias  $Y$ ) a partir de um conjunto de entradas de variáveis aleatórias  $X$

(HASTIE e colab., 2009; WASSERMAN, 2004). Na literatura, nomeia-se as entradas como preditores, atributos de entrada ou variáveis independentes e, as saídas são denominadas como respostas ou variáveis dependente. Assim, os modelos de classificação fazem uma representação abstrata entre os atributos de entrada e a respectiva classe de saída, e podem servir como uma ferramenta de distinção entre os objetos ou na predição de classes (RAMOS, 2022).

Diante da necessidade de melhor entendimento do processo de envelhecimento humano, os classificadores têm sido bastante utilizados para prever eventos relacionados à idade, os quais os principais algoritmos de classificação utilizados nessa área são o KNN, RF, NB e SVM (ALIZADEH e colab., 2021; BEGG e colab., 2005; CUAYA-SIMBRO e colab., 2021; FUJIO e TAKEUCHI, 2021; FUKUCHI e colab., 2011; MANNINI e colab., 2016; TAREKEGN e colab., 2020; TAVAKOLAN e colab., 2011; WU e WANG, 2008).

Os modelos utilizados nesse trabalho estão descritos nos itens 2.6.1, 2.6.2, 2.6.3, 2.6.4.

### 2.6.1 Máquina Vetor Suporte (SVM)

O algoritmo de classificação SVM (do inglês *Support Vector Machine*) é método que ajusta uma função discriminante, que pode ou não ser linear, e determina o hiperplano ótimo, que maximiza a distância entre os pontos a serem classificados, permitindo sua separação (BI e colab., 2019; RAMOS, 2022).

O SVM é tradicionalmente utilizado para classificação binária, que separa os dados em duas classes, entretanto, pode ser aplicado em múltiplas comparações para classificações multiclases (BI e colab., 2019).

Algumas observações não podem ser separadas pelo hiperplano criado, sendo necessária sua transformação antes da separação, para tanto, o algoritmo aplica uma transformação de dados chamada “função de *Kernel*” (BI e colab., 2019). *Kernel* é uma função matemática utilizada para casos não linearmente separáveis, a qual retorna o produto escalar das imagens de seus argumentos, possibilitando que o espaço de busca anteriormente não separável, se torne separável. Em outras palavras, a função *Kernel* é um modelo matemático que, através de polinômios, traça um modelo capaz de criar um hiperplano para separar diferentes conjuntos de dados em um ambiente multidimensional (RAMOS, 2022; ZHIBIN LIU e LI BAI, 2008).

Entre as funções de *Kernel* mais comuns encontradas temos a polinomial, linear ou gaussiana, sendo que a seleção da função ideal geralmente requer simulações, depende dos

dados analisados e pode alterar de forma significativa a acurácia do classificador (BI e colab., 2019; PERES, Luciano e ANDRADE, 2016).

### 2.6.2 K-vizinho mais próximo (KNN)

O algoritmo k-vizinho mais próximo (do inglês *k-nearest Neighbor*) assume que todas as instâncias correspondem a pontos no espaço n-dimensional, sendo n a quantidade de atributos. Embora a abordagem utilizando instâncias seja um método simples de classificar os dados, têm sido bastante utilizada no reconhecimento de padrões, análise exploratória de dados e problemas de mineração de dados, sendo adequada para solucionar problemas complexos (BHATTACHARYA e colab., 2012).

O algoritmo KNN utiliza a hipótese de que dados similares tendem a se concentrarem em uma mesma região do espaço, assim, os vizinhos mais próximos de uma instância são definidos a partir do cálculo da medida de proximidade (RAMOS, 2022). O algoritmo utiliza um conjunto de dados conhecido (dados de treinamento) e classifica o novo dado a partir do cálculo da distância entre eles, sendo que a nova classe será a mesma do dado que estiver mais próximo. Em outras palavras, o algoritmo KNN calcula o K vizinhos mais próximos e, se os vizinhos mais próximos forem majoritariamente de uma classe, o novo dado será classificado de acordo com essa classe.

O termo K é o parâmetro referente à quantidade de vizinhos mais próximos que serão utilizados no processo de classificação, o qual o valor de K interfere diretamente no processo decisório e no tempo de processamento das informações (BHATTACHARYA e colab., 2012). Além disso, a escolha da medida de proximidade utilizada no processo de classificação, é determinante para o sucesso do algoritmo (RAMOS, 2022).

Dentre os métodos de cálculo da distância dos dados, destaca-se a Distância Euclidiana entre os pontos bidimensionais  $P(P_x, P_y)$  e  $Q(Q_x, Q_y)$ , calculada conforme equação

2.1.

$$D(P, Q) = \sqrt{(P_x - Q_x)^2 + (P_y - Q_y)^2} \quad \text{equação (2.1)}$$

Assim, a classificação utilizando o algoritmo KNN envolve duas principais etapas: (i) cálculo da distância entre a nova amostra e todas as amostras de treinamento (nesse trabalho dada pela distância euclidiana) e, (ii) a nova amostra é atribuída a classe das amostras mais próximas (KHOURY e colab., 2019).

### 2.6.3 Floresta Aleatória (RF)

O classificador RF (do inglês *Random Forest*) é um algoritmo baseado em árvores de decisão (*decision trees* - DTs), sendo as DTs estruturas de predição mais simples e que apresentam uma acurácia baixa quando comparadas a outros classificadores (HASTIE e colab., 2009). Para contornar a baixa acurácia das árvores de decisão, o algoritmo RF cria de forma aleatória diversas árvores de decisão, combinando o resultado de todas elas para chegar no resultado final.

Para entender como o algoritmo RF funciona, primeiramente precisamos entender como as árvores de decisão trabalham para classificar os dados. O algoritmo das DTs são semelhantes a um fluxograma, no qual criam uma série de regras de decisão baseadas em variáveis de entrada categórica para prever um resultado (BI e colab., 2019). As árvores são formadas por raiz (*root*), nós (*nodes*), que representam as condições a serem analisadas para a tomada de decisão e, folhas (*leafs*), representando as possíveis categorias dos dados. Os nós representam as condições a serem analisadas para a tomada de decisão, se atendida, o fluxo segue por um ramo, caso contrário segue por outro ramo, levando ao próximo nó até a finalização da árvore, assim, diante da condição satisfeita, ele fará a previsão da variável dependente.

Cada árvore é construída usando um subconjunto de treinamento gerado aleatoriamente a partir do conjunto de dados original usando a técnica *Bootstrap* (KHOURY e colab., 2019). Assim, o modelo utilizado no algoritmo RF analisa as  $n$  diferentes árvores de decisão criadas, onde cada uma delas dará um resultado e aquele resultado que mais vezes foi escolhido será o previsto (KABIRAJ e colab., 2020).

### 2.6.4 Naive Bayes (NB)

O algoritmo NB é um modelo de classificação probabilística baseado no teorema de *Bayes*, que faz suposições “ingênuas” de independência entre as variáveis preditivas (BI e colab., 2019).

O método calcula a probabilidade associada a cada condicional de classe possível em um conjunto de covariáveis (BI e colab., 2019), assim, calcula a probabilidade de um evento A acontecer, dado que um evento B conhecido já ocorreu, conforme mostra a equação 2.2.

$$P(A | B) = \frac{P(B | A) * P(A)}{P(B)} \quad \text{equação (2.2)}$$

Dado um sistema X composto por n variáveis independentes e uma classe y (variável dependente), temos  $X = \{x_1, x_2, x_3, \dots, x_n, y\}$ , onde y pode assumir valores de  $y_1$  ou  $y_2$ . Em aprendizagem de máquinas ao aplicar a equação 2.2 em um dado específico de X teremos as equações 2.3 e 2.4, que calculam as probabilidades das classes  $y_1$  e  $y_2$  respectivamente.

$$P(y_1 | x_1, x_2, x_3, \dots, x_n) = \frac{P(x_1 | y_1) * P(x_2 | y_1) * \dots * P(x_n | y_1) * P(y_1)}{P(x_1) * P(x_2) * \dots * P(x_n)} \quad \text{equação (2.3)}$$

$$P(y_2 | x_1, x_2, x_3, \dots, x_n) = \frac{P(x_1 | y_2) * P(x_2 | y_2) * \dots * P(x_n | y_2) * P(y_2)}{P(x_1) * P(x_2) * \dots * P(x_n)} \quad \text{equação (2.4)}$$

A partir dos cálculos da probabilidade das classes, temos que a classe y de X será aquela que apresentar maior valor de P.

# Capítulo 3

## MATERIAIS E MÉTODOS

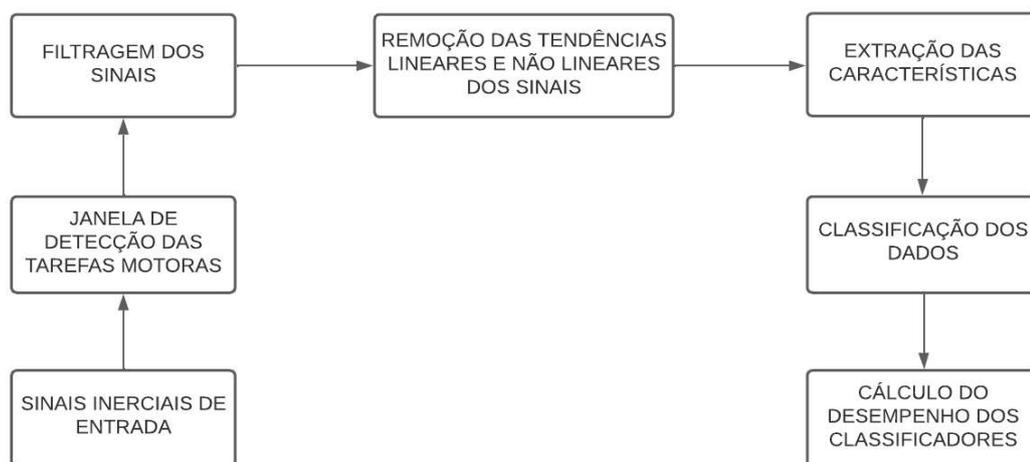
---

*Neste capítulo serão apresentados os materiais e métodos utilizados para desenvolvimento desta pesquisa.*

### 3.1 Introdução

Este trabalho refere-se a um estudo observacional analítico transversal, com aprovação da Comissão Nacional de Ética em Pesquisa (CONEP).

As etapas de realização deste trabalho estão representadas na Figura 3.1, o qual a partir do fluxograma permite visualizar o passo a passo utilizado para alcançar o objetivo geral deste estudo.



**Figura 3.1 - Fluxograma da realização do trabalho**

Após a coleta de dados, o qual o item 3.2 deste capítulo detalha como e onde foram coletados, os critérios de elegibilidade dos voluntários participantes e o protocolo experimental, é necessário analisá-los e, para isto, faz-se o uso do processamento de sinais, que visa minimizar erros, melhorar a qualidade do sinal e a estabilidade do sistema. O item 3.3 aborda como foi realizada a filtragem do sinal e a remoção das tendências lineares e não lineares dos sinais. Os itens 3.4, 3.5, 3.6 e 3.7 relatam sobre a extração de características dos sinais, para posteriormente, classificação dos dados e avaliação da performance dos classificadores.

## **3.2 Coleta de dados**

Os voluntários que concordaram em participar da pesquisa assinaram o Termo de Consentimento Livre e Esclarecido, onde foram alertados sobre os objetivos do estudo, como seria realizada a coleta de dados e, por fim, sobre a divulgação dos resultados.

A coleta dos dados foi realizada de forma não invasiva, com os devidos cuidados e tratamentos da pele, sem qualquer risco à saúde e a integridade física e/ou moral dos voluntários, além de não oferecer nenhum benefício financeiro aos mesmos (ZARUZ, 2016).

Neste item foram abordadas as estratégias adotadas para seleção dos voluntários, os equipamentos e dispositivos utilizados na coleta, e o protocolo experimental para a coleta dos dados.

### **3.2.1 Local da Coleta e População Recrutada**

Este estudo utilizou os dados coletados por Zaruz (2016), o qual foi realizada no Núcleo de Inovação e Avaliação Tecnológica em Saúde (NIATS) da Universidade Federal de Uberlândia (UFU) e, para àqueles indivíduos com idades mais avançadas, a coleta foi realizada na própria residência, evitando assim deslocamentos inconvenientes.

Para seleção dos participantes, o critério de inclusão adotado foi indivíduos saudáveis com faixa etária entre 20 a 98 anos.

Já os critérios de exclusão adotados foram:

- (1) Indivíduos que apresentassem ou tivessem histórico de doenças neuromotoras ou neurodegenerativas associadas;
- (2) Indivíduos que tivessem feito uso de medicamentos que pudessem afetar o movimento voluntário.

Para este estudo foram incluídos noventa e nove (99) voluntários de ambos os sexos, conforme mostra Tabela 3.1.

**Tabela 3.1 - Amostras dos grupos**

<b>Faixa etária</b>	<b>Número de participantes (n)</b>
<b>20 – 29 anos</b>	13
<b>30 – 39 anos</b>	12
<b>40 – 49 anos</b>	13
<b>50 – 59 anos</b>	15
<b>60 – 69 anos</b>	11
<b>70 – 79 anos</b>	14
<b>80 – 89 anos</b>	13
<b>90 – 98 anos</b>	8
<b>Total</b>	99

Os participantes foram divididos em dois grupos, sendo o primeiro constituído por indivíduos adultos com faixa etária entre 20 a 59 anos (Grupo Adulto - GA), e o segundo grupo constituído por indivíduos idosos com faixa etária entre 60 a 98 anos (Grupo Idoso - GI), conforme mostra Tabela 3.2.

**Tabela 3.2 - Características demográficas dos participantes incluídos neste estudo**

<b>Características</b>	<b>Grupo Adultos</b>	<b>Grupo Idosos</b>
<b>Número de voluntários</b>	53	46
<b>Idade (anos) (média ± SD)</b>	40.5 ± 12	78.3 ± 10.5
<b>Sexo/número de voluntários</b>	M = 25 / F = 28	M = 21 / F = 25

M – Masculino, F – Feminino, SD – Desvio Padrão.

### 3.2.2 Dispositivos utilizados na coleta dos dados

O hardware utilizado na coleta dos dados foi o TREMSEN (*Precise Tremor Sensing Technology*), ilustrado na Figura 3.2. O dispositivo biomédico foi criado em 2014 pelo NIATS e a patente foi depositada no Instituto Nacional da Propriedade Industrial (INPI) unidade DIREG-MG no dia 19/09/2014, com número de processo (BR 10 2014 023282 6).



**Figura 3.2 - Hardware TREMSEN**

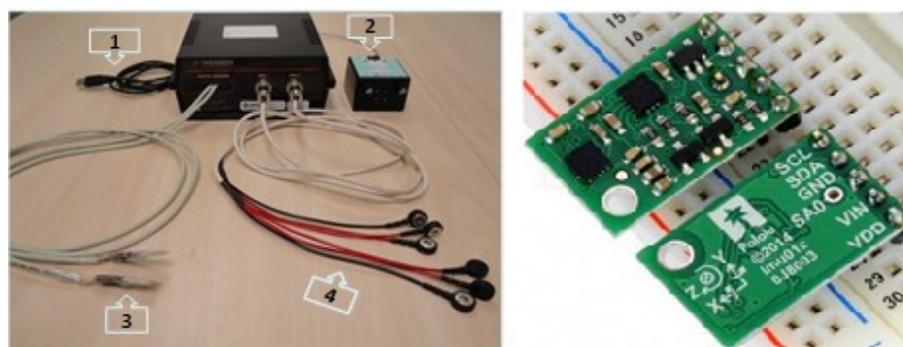
**Fonte: (ZARUZ, 2016)**

O dispositivo possui um sensor de eletromiografia (EMG) de superfície e duas unidades de medição inercial (IMUs), onde cada IMU contém três sensores inerciais, os quais realizam medições em três direções ortogonais: acelerômetro, giroscópio e magnetômetro. O sensor inercial utilizado, é compreendido por um chip MinIMU, que contém um acelerômetro triaxial, um magnetômetro triaxial (*Stmicroelectronics*, 2013b), e um giroscópio triaxial (*Stmicroelectronics*, 2013a). A sensibilidade do giroscópio, acelerômetro e magnetômetro foi configurada para  $\pm 245^\circ/s$ ,  $\pm 2g$  e  $\pm 2$  gauss respectivamente, conforme estudos de *Machado e colaboradores* (2016).

A comunicação com o microcontrolador ocorre por meio do protocolo I<sup>2</sup>C especificado pela *Philips Semiconductors*, a conversão dos dados analógicos para digital é realizada pelo conversor A/D de 12 bits. O microcontrolador lê os as informações advindas dos sensores inerciais e transmite os dados para o computador via comunicação *Universal Serial Bus* (USB).

Os sinais foram amostrados a 50 Hz e as informações advindas dos sensores inerciais foram armazenadas em formato de texto em um computador.

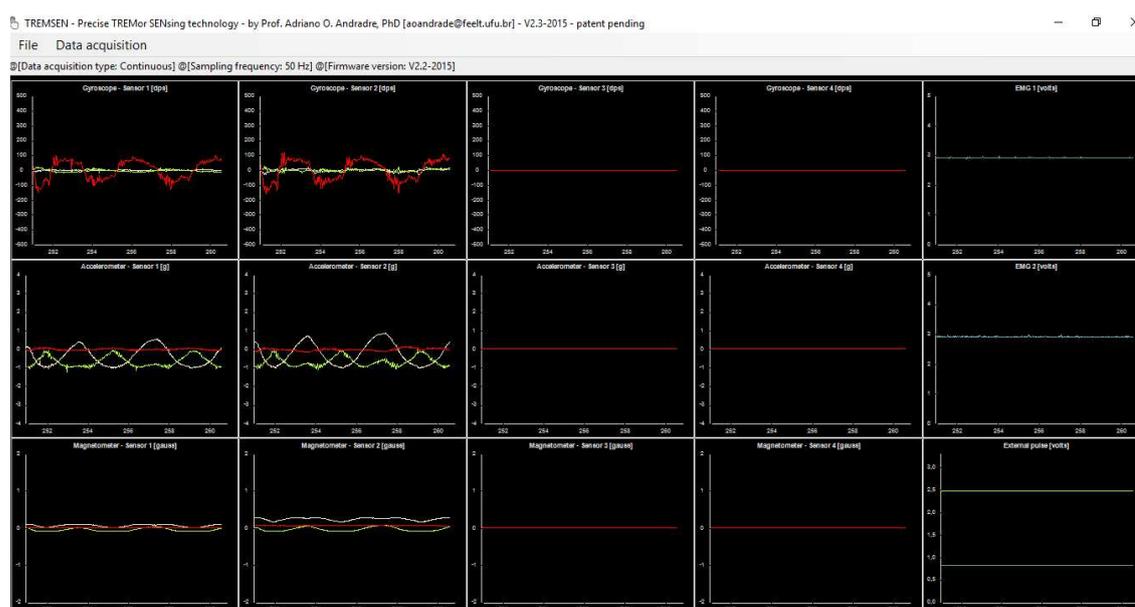
A Figura 3.3 mostra os componentes do hardware TREMSEN, a placa MinIMU.



**Figura 3.3 - (A) Componentes do TREMSEN, 1 - cabo USB; 2 - Bateria EMG; 3 - Sensores Inerciais; 4 - Eletrodos EMG de superfície; (B) Placa MinIMU com Sensor de movimento**

**Fonte: (ZARUZ, 2016)**

O *software* utilizado foi desenvolvido em C# (Microsoft), para armazenamento e visualização os dados em tempo real, conforme Figura 3.4.



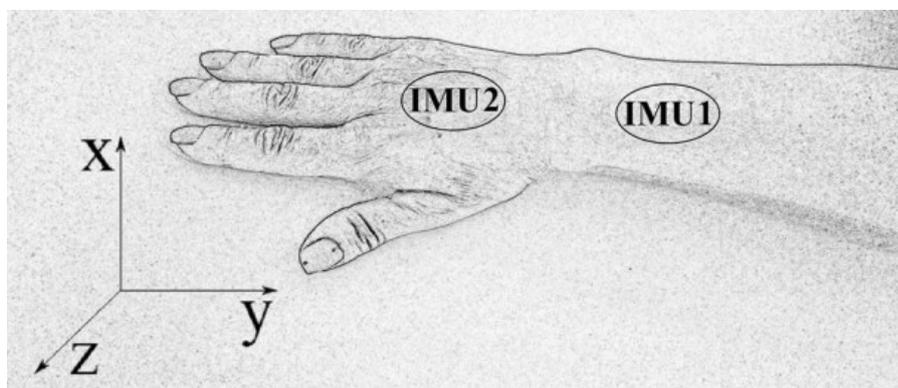
**Figura 3.4 - Tela do software TREMSEN com visualização em tempo real**

**Fonte: (ZARUZ, 2016)**

### 3.2.3 Protocolo experimental para coleta dos dados

Para coleta dos dados foram utilizados dois sensores inerciais. O IMU 1 foi posicionado na região do terço distal do antebraço da mão dominante seguindo o alinhamento do terceiro dedo e, o IMU 2 foi posicionado no dorso da mão dominante, seguindo o mesmo

alinhamento do primeiro sensor. O eixo X foi orientado na direção vertical, o eixo Y na direção médio-lateral e, o eixo Z na direção anteroposterior (ZARUZ, 2016), conforme mostra Figura 3.5.



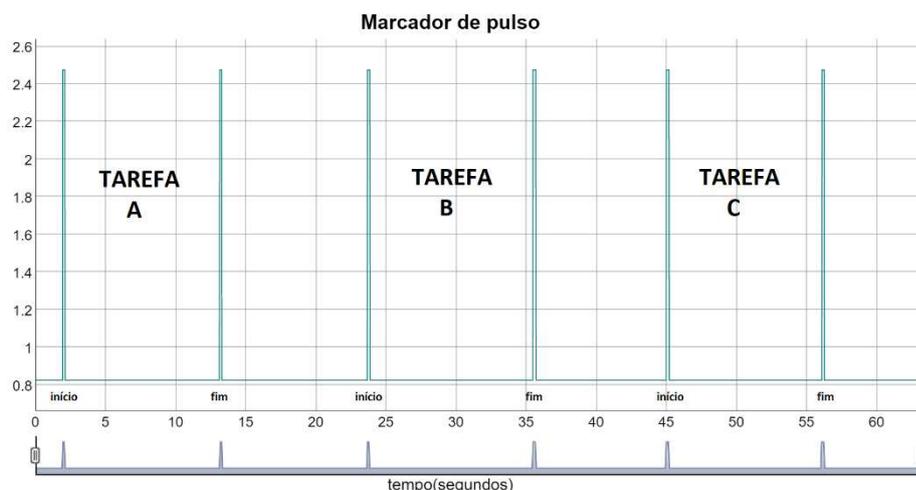
**Figura 3.5 - Posicionamento dos sensores inerciais e direção dos eixos**

O protocolo de coleta de dados foi realizado com o membro superior dominante, com o antebraço em semiflexão e sem apoio. Os voluntários realizaram três tarefas sequenciais, com duração de no mínimo cinco (5) segundos em cada uma das tarefas, sendo a sequência das tarefas - A, B e C, detalhadas a seguir (ZARUZ, 2016):

- (A) Repouso;
- (B) Movimentos de pinça polpa a polpa com todos os dedos;
- (C) Movimentos de supinação e pronação.

Cada voluntário realizou o protocolo experimental três vezes.

Para detecção de eventos importantes durante a coleta, o janelamento foi realizado através do marcador de pulso, utilizado durante a coleta dos dados, sinalizando o início e fim de cada uma das tarefas, conforme Figura 3.6.



**Figura 3.6 - Janelamento do sinal utilizando o marcador de pulso. (Tarefa A) repouso com membro superior dominante; (Tarefa B) movimento de pinça polpa a polpa; (Tarefa C) movimento de supinação/pronação**

### 3.3 Processamento dos sinais

Na prática, a análise de dados possibilita determinar parâmetros necessários para a construção de modelos a fim de representar um fenômeno (HUANG e colab., 1998). Por exemplo, na medicina, a geração de sinais biomédicos a partir de sistemas fisiológicos, possibilita a extração de característica que contribuem para a exploração e monitoramento desses sistemas e sua condição de saúde ao longo do tempo, além de permitir a predição de possíveis efeitos patológicos (CASTIGLIONI e colab., 2020).

Para processamento dos sinais foi utilizado o *software* R, que é um *software* livre para manipulação, análise e visualização de dados, com código aberto e linguagem acessível.

O pré processamento dos sinais inclui a filtragem digital do sinal e remoção de tendências lineares e não lineares.

Com intuito de remover as componentes indesejadas de baixa e alta frequência, foi aplicado um filtro *Butterworth* de 5ª ordem passa banda, com frequência de corte entre 1 e 16 Hz (JEON e colab., 2017).

Para eliminar as tendências lineares dos sinais, primeiramente foi feito o cálculo do vetor resultado (R) de cada sinal, conforme mostra equação 3.1 abaixo.

$$R = \sqrt{x^2 + y^2 + z^2} \quad \text{equação (3.1)}$$

Onde x, y e z são as coordenadas individuais medida pelos sensores ao longo dos respectivos eixos.

Posteriormente, o valor de R foi subtraído da sua média e, o sinal resultante foi utilizado para extrair as características de interesse.

### 3.4 Extração das características dos sinais

Estudos têm utilizado algumas das principais características possíveis de se extrair de sinais biomédicos. As características usadas neste estudo são as mesmas utilizadas por *Calil e colaboradores*. (2020) e *Peres e colaboradores*. (2021), e são descritas nas seções “RMS – Root Mean Square” (A. PHINYOMARK, S. HIRUNVIRIYA, 2010; GRUSS e colab., 2015; RESIDENTE, 2019; ZHANG e colab., 2019) e “Kurtosis – flattening” (KHALILI e MORADI, 2009; RIBEIRO e colab., 2012; RIZON e colab., 2007).

Características extraídas a partir do cálculo de RMS, PICO, MAV, MAVFD, MAVSD estão relacionados à amplitude do sinal (PERES, Luciano Brinck e colab., 2021), ou seja, avaliam o quanto o local em que o sensor foi alocado se movimentou.

RMS – Raiz Média Quadrática é dada pela equação 3.2 (A. PHINYOMARK, S. HIRUNVIRIYA, 2010; GRUSS e colab., 2015; RESIDENTE, 2019; ZHANG e colab., 2019)

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i)^2} \quad \text{equação (3.2)}$$

Onde o n é o número de elementos de X, com  $X = \{x_1, x_2, x_3, \dots, x_n\}$ , sendo  $x_n$  o n-ésimo elemento.

PICO - valor máximo de um vetor, o qual considera apenas valores positivos da janela, dado pela equação 3.3 (GRUSS e colab., 2015)

$$PICO = \max \{X_i\}_{i=1}^n \quad \text{equação (3.3)}$$

MAV – valor médio absoluto, calculado a partir da equação 3.4 (A. PHINYOMARK, S. HIRUNVIRIYA, 2010; ENGLEHART e HUDGINS, 2003; GRUSS e colab., 2015)

$$MAV = \frac{1}{S} \sum_{m=1}^S |X_m| \quad \text{equação (3.4)}$$

Onde S é o número de amostras por janela e  $X_m$  é o m-ésimo amostra da janela.

MAVFD – valor médio absoluto da primeira diferença, calculado pela equação 3.5 (GRUSS e colab., 2015; KHALILI e MORADI, 2009; VYZAS e PICARD, 1998)

$$MAVFD = \frac{1}{N-1} \sum_{n=1}^{N-1} |X_{n+1} - X_n| \quad \text{equação (3.5)}$$

MAVSD – valor médio absoluto da segunda diferença, dado pela equação 3.6 (GRUSS e colab., 2015; VYZAS e PICARD, 1998)

$$MAVSD = \frac{1}{N-2} \sum_{n=1}^{N-2} |X_{n+2} - X_n| \quad \text{equação (3.6)}$$

A frequência do sinal analisa a repetição das oscilações por unidade de tempo e, o cálculo de ZC, FPICO, FMEDIA, F50, F80, Power3.5\_7.5 estão relacionados com essa medida (PERES, Luciano Brinck e colab., 2021).

ZC – *zero crossing* calcula quantas vezes o sinal atravessa o eixo das abcissas (eixo x). (A. PHINYOMARK, S. HIRUNVIRIYA, 2010; ENGLEHART e HUDGINS, 2003; GRUSS e colab., 2015; ZHANG e colab., 2019)

FPICO – frequência na qual a potência máxima ocorre, dada pela equação 3.7 (GROSS e colab., 2000; KHANAM e AHMAD, 2015; MCDONALD e colab., 2019)

$$FPICO = \text{máximo: } P_n \quad \text{equação (3.7)}$$

Onde o  $P_n$  é o espectro de potência.

FMEDIA – frequência média, calculada pela equação 3.8 (A. PHINYOMARK, S. HIRUNVIRIYA, 2010; GROSS e colab., 2000; GRUSS e colab., 2015; KHANAM e AHMAD, 2015; RESIDENTE, 2019)

$$FMEDIA = \frac{\sum_{n=1}^n (P_n(n) * f_n(n))}{\sum_{n=1}^n P_n(n)} \quad \text{equação (3.8)}$$

Onde  $f_n$  é o vetor de frequências de  $P_n$

F50 – frequência mediana é calculada pela equação 3.9 (A. PHINYOMARK, S. HIRUNVIRIYA, 2010; FERNANDEZ e colab., 2012; GROSS e colab., 2000; GRUSS e colab., 2015; MCDONALD e colab., 2019; RESIDENTE, 2019)

$$F50 = \sum_{n=1}^{F50} P_n(n) = \sum_{F50}^n P_n(n) = \frac{1}{2} \sum_{n=1}^n P_n(n) \quad \text{equação (3.9)}$$

F80 – frequência da potência total de  $P_n$  abaixo de 80%, dada pela equação 3.10 (GROSS e colab., 2000; RIBEIRO e colab., 2012)

$$F80 = \sum_{n=1}^{F80} P_n(n) = 0.8 * \sum_{n=1}^n P_n(n) \quad \text{equação (3.10)}$$

Power3.5\_7.5 – potência na banda de frequência entre 3.5 – 7.5 Hz, calculado pela equação 3.11 (BUTT e colab., 2017)

$$Power_{3.5_7.5} = \sum_{f_n=3.5}^{f_n=7.5} P_n(n) \quad \text{equação (3.11)}$$

A variabilidade estatística das tarefas motoras permite quantificar o padrão de variabilidade das tarefas, a partir do desvio médio padrão dos valores de uma série temporal estimada durante a execução do movimento. Neste caso, o resultado é uma medida (valor médio) que representa uma tendência linear global, juntamente com o desvio padrão,

representando a dispersão dos dados em torno da média (STERGIOU; HARBOURNE; CAVANAUGH, 2006). Características como VAR, RANGE e IntA estão relacionadas à variabilidade do sinal (PERES, Luciano Brinck e colab., 2021).

VAR – variância, dada pela equação 3.12 (A. PHINYOMARK, S. HIRUNVIRIYA, 2010; GRUSS e colab., 2015; ZHANG e colab., 2019)

$$VAR = \sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad \text{equação (3.12)}$$

Onde  $\sigma$  é o desvio padrão e  $\bar{X}$  é a média das amostras.

RANGE – faixa de amplitude, diferença entre o valor máximo e mínimo observados, é calculada pela equação 3.13 (CAVALHEIRO e colab., 2009; GRUSS e colab., 2015)

$$RANGE = \max \{X_{ij}\}_{i=1}^n - \min \{X_{ij}\}_{i=1}^n \quad \text{equação (3.13)}$$

IntA – intervalo interquartil, dada pela equação 3.14 (ANTONELLI e colab., 2020; GRUSS e colab., 2015; PEREZ e TAH, 2020)

$$IntIA = Q_3 - Q_1 \quad \text{equação (3.14)}$$

Onde  $Q_3$  é o terceiro quartil e  $Q_1$  é o primeiro quartil.

As características *Skewness* e *Curtose* estão relacionadas com a distribuição dos dados, na qual mede a forma do sinal a partir da dispersão que caracteriza o achatamento da curva da função de distribuição (PERES, Luciano Brinck e colab., 2021).

*Skewness* – assimetria, calculada a partir da equação 3.15 (KHALILI e MORADI, 2009; RIBEIRO e colab., 2012; RIZON e colab., 2007)

$$Skewness = \frac{\frac{1}{n} \sum_{i=1}^n (X - \bar{X})^3}{\sigma^3} \quad \text{equação (3.15)}$$

*Curtose* – achatamento, dada pela equação 3.16 (KHALILI e MORADI, 2009; RIBEIRO e colab., 2012; RIZON e colab., 2007)

$$\text{Curtose} = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^4}{\sigma^4} \quad \text{equação (3.16)}$$

Por fim, temos as características *FuzzyEn* e *ApEn* que estão relacionadas com a entropia do sinal (PERES, Luciano Brinck e colab., 2021), as quais são medidas ligadas à complexidade de um sistema, permitindo uma avaliação do seu comportamento temporal (PINCUS, 1991).

*ApEn* – entropia aproximada, calculada a partir da equação 3.17 (GRUSS e colab., 2015; KHANAM e AHMAD, 2015; PINCUS, 1991; RIBEIRO e colab., 2012; ZHANG e colab., 2019)

$$\text{ApEn}(m, \dots, r, \dots, N) = C^m(r) - C^{m+1}(r) \quad \text{equação (3.17)}$$

Onde:  $C^m(r) = (N - m + 1)^{-1} \sum_{i=1}^{N-m+1} \ln(C_i^m(r))$ ;

Sendo *m* o tamanho da janela de comparação, *r* a tolerância e *ln* o logaritmo natural.

*FuzzyEn* – entropia *Fuzzy*, calculada a partir da equação 3.18 (CHEN e colab., 2007; GRUSS e colab., 2015; ZHANG e colab., 2019)

$$\text{FuzzyEn}(m, \dots, r, \dots, N) = \ln(P^m(r)) - \ln(P^{m+1}(r)) \quad \text{equação (3.18)}$$

Onde:

$$P^m(r) = (N - m)^{-1} \sum_{i=1}^{N-m} P_i^m(r);$$

$$P^{m+1}(r) = (N - m)^{-1} \sum_{i=1}^{N-m} P_i^{m+1}(r);$$

$$P_i^m(r) = (N, -, m, +, 1)^{-1} \sum_{j=1, j \neq i}^{N-m} d^m[x_i, x_j]$$

Assim, para este estudo teremos o cálculo de 5 características relacionadas com a amplitude do sinal, 6 características relacionadas com a frequência do sinal, 3 características relacionadas com a variabilidade do sinal, 2 características relacionadas com a distribuição dos dados e 2 características relacionadas com a entropia do sinal, totalizando 18 características.

### 3.5 Classificadores

Para apresentação das características na mesma escala adimensional, os dados foram normalizados utilizando o escore  $Z$ , dada pela equação (3.19).

$$ZS = \frac{\text{value} - \mu}{\sigma} \quad \text{equação (3.19)}$$

Onde:  $\mu$  é a média das características e  $\sigma$  seu desvio padrão.

Diante da dificuldade em escolher um único classificador, pesquisadores têm optado por usar vários algoritmos de classificação e avaliar qual possui a melhor performance e em quais condições esta foi obtida (BOUROUHOU e colab., 2016).

Para este estudo, os classificadores utilizados foram KNN, SVM, RF e NB. Esses classificadores foram escolhidos devido a sua utilização em diversos estudos sobre envelhecimento (ALIZADEH e colab., 2021; BEGG e colab., 2005; CUAYA-SIMBRO e colab., 2021; FUJIO e TAKEUCHI, 2021; FUKUCHI e colab., 2011; MANNINI e colab., 2016; TAREKEGN e colab., 2020; TAVAKOLAN e colab., 2011; WU e WANG, 2008).

A seleção dos parâmetros de cada classificador foi realizada através de simulações, os quais foram selecionados aqueles que obtiveram melhores respostas.

### 3.6 Peso das características

No campo de modelação de dados, é importante identificar quais características são relevantes para caracterização dos dados, uma vez que tratando-se de conjunto de dados, na maioria dos casos, apenas um subconjunto de características são relevantes, sendo que as demais podem atuar como confundidoras ou serem irrelevantes para o estudo (URBANOWICZ e colab., 2018).

Assim, a classificação das características foi realizada usando a mesma abordagem que *Peres e colaboradores*. (2021) utilizou em seu estudo. As características foram hierarquizadas de acordo com seu peso para a classificação dos grupos, calculado através do pacote *CORElearn* e da função *attrEval* do *software* R, o qual foi utilizado o estimador *ReliefF* e

com  $k = 1$ . Neste método, a classificação das características foi efetuada de acordo com a relevância das características analisadas na classificação dos grupos, utilizando o algoritmo que utiliza conceitos de vizinhos mais próximos (KNN).

A extração de 18 características de cada sensor inercial, totalizou 108 características de cada tarefa, uma vez que cada sensor possui um acelerômetro, um giroscópio e um magnetômetro. Por tratar de três diferentes tarefas realizadas, foram extraídas um total de 324 características. A Tabela 3.3 mostra detalhadamente a quantidade de características extraídas.

**Tabela 3.3 - Quantidade de características extraídas**

		Quantidade de características extraídas			
		Tarefa 1	Tarefa 2	Tarefa 3	Total
<b>Sensor Inercial 1</b>	Acelerômetro 1	18	18	18	54
	Giroscópio 1	18	18	18	54
	Magnetômetro 1	18	18	18	54
<b>Sensor Inercial 2</b>	Acelerômetro 2	18	18	18	54
	Giroscópio 2	18	18	18	54
	Magnetômetro 2	18	18	18	54
<b>Total</b>		108	108	108	324

Os classificadores foram alimentados primeiramente com 5% das características com maior peso e, posteriormente, foram adicionadas características para alimentar os classificadores em incrementos de 5% das características, sempre considerando a sequência dos pesos das características para classificação, até que todas características fossem adicionadas para o cálculo das métricas.

Após hierarquizar as características de acordo com sua relevância e alimentar os classificadores com incrementos de 5% das características mais importantes, foram calculados os pesos dos parâmetros, incluindo a análise das três diferentes tarefas, dois IMUs localizados em diferentes partes do membro superior dominante, cada sensor e cada grupo de característica.

### 3.7 Medidas de Desempenho

As medidas de desempenho de um modelo de classificação são baseadas na quantidade de registros preditos corretamente e de forma incorreta, conforme informações contidas na matriz de confusão (Tabela 3.4) (RAMOS, 2022).

**Tabela 3.4 - Matriz de confusão**

		Classe Predita	
		Resultado Positivo	Resultado Negativo
Classe original	Positivo Real	TP	FN
	Negativo Real	FP	TN

TP – Verdadeiro Positivo, FP – Falso Positivo, FN – Falso Negativo – TN Verdadeiro Negativo.

Sendo:

- Verdadeiro Positivo (*True Positive* – TP): corresponde aos registros preditos como positivos, e que realmente pertencem à essa classe;
- Falso Positivo (*False Positive* – FP): corresponde aos registros preditos positivos, sendo pertencentes à classe negativa;
- Verdadeiro Negativo (*True Negative* – TN): corresponde aos registros preditos negativos, sendo verdadeiramente dessa classe;
- Falso Negativo (*False Negative* – FN): corresponde aos registros preditos na classe negativa, sendo pertencentes à classe positivo;

As seguintes métricas foram calculadas para avaliar o desempenho dos classificadores:

Sensibilidade: quantidade de dados classificados como pertencentes à classe positiva e que realmente pertencem à essa classe, dada pela equação 3.20;

$$\text{Sensibilidade} = \frac{TP}{TP + FN} \quad \text{equação (3.20)}$$

Especificidade: quantidade de dados classificados como pertencentes à classe negativa e que realmente pertencem à essa classe, dada pela equação 3.21;

$$\textit{Especificidade} = \frac{TN}{TN + FP} \quad \text{equação (3.21)}$$

Acurácia: corresponde ao número de acertos da classe, dada pela equação 3.22;

$$\textit{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad \text{equação (3.22)}$$

Precisão: frequência em que a condição positiva é corretamente classificada, dada pela equação 3.23;

$$\textit{Precisão} = \frac{TP}{TP + FP} \quad \text{equação (3.23)}$$

### 3.8 Divisão dos Dados

Este estudo utilizou o Projeto R para computação estatística para realizar análises de dados. Para tanto, foi utilizada a validação cruzada de dez vezes para avaliar o desempenho da classificação. O estudo dividiu aleatoriamente os dados em 50% para treinamento do modelo e os 50% restantes para testes. Os dados utilizados para treinamento do modelo não foram utilizados para teste do modelo.

# Capítulo 4

## RESULTADOS

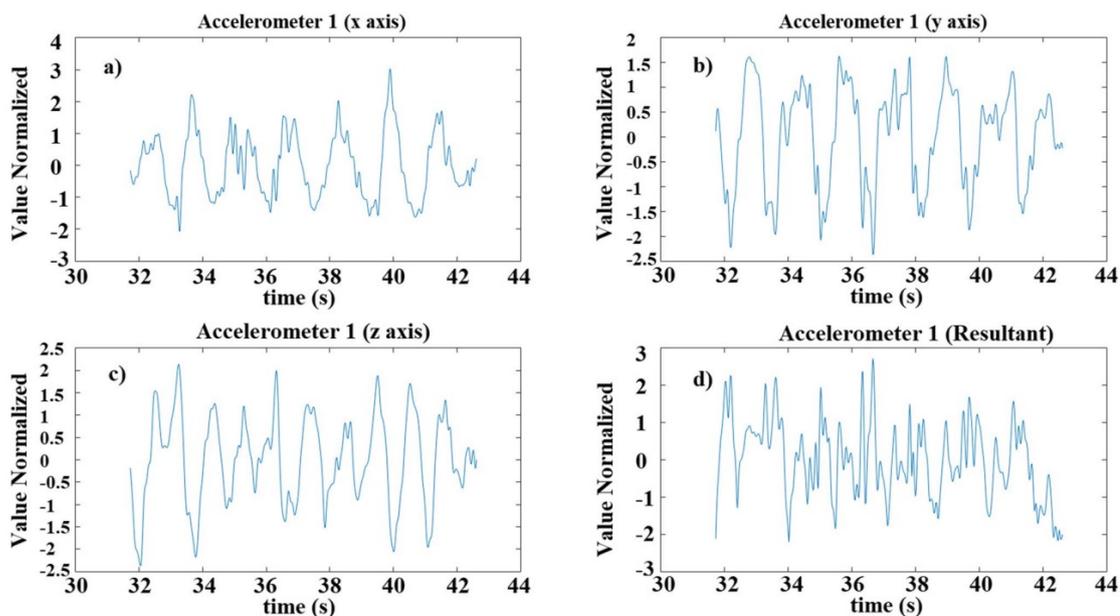
---

---

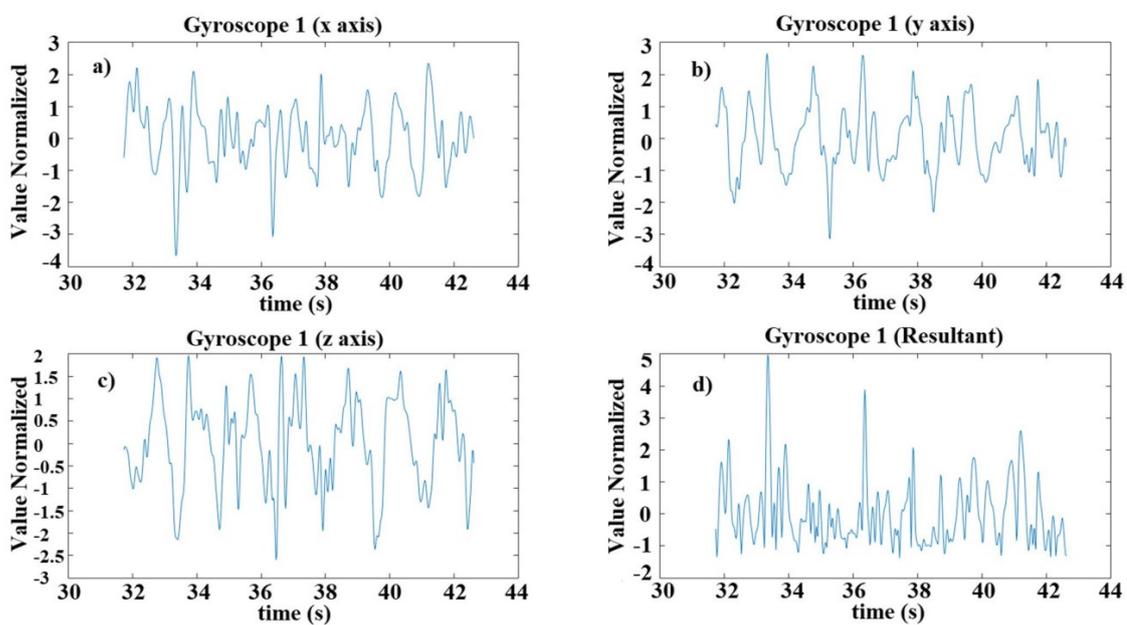
*Este capítulo descreve os resultados encontrados a partir dos materiais e métodos discutidos anteriormente.*

### 4.1 Resultados encontrados

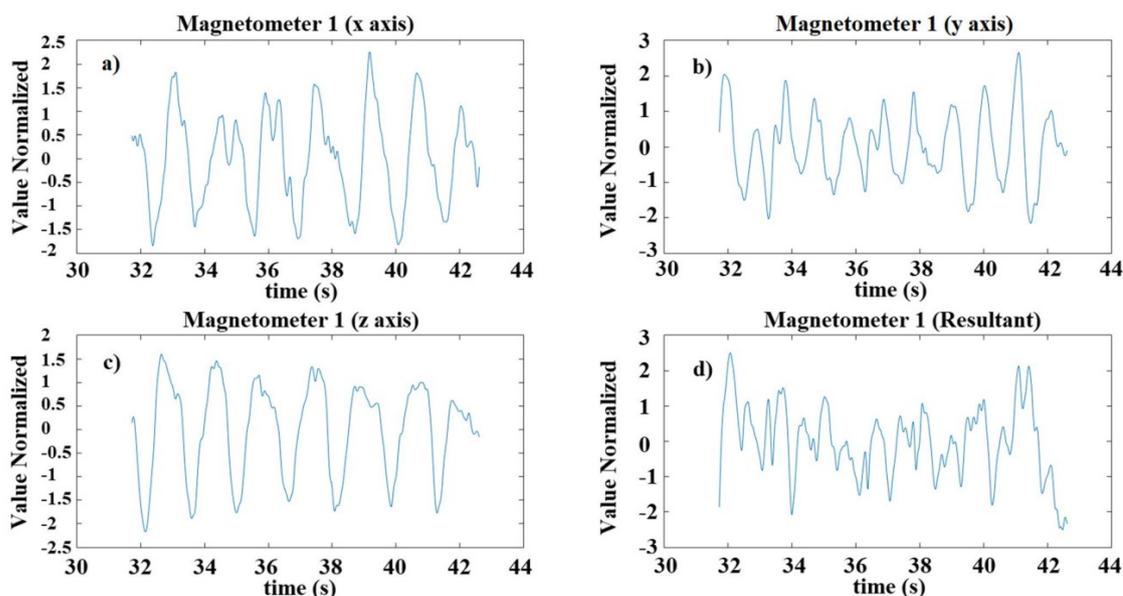
Os sinais coletados pela pesquisadora Maria José Ferreira Zaruz estão apresentados nas Figuras 4.1, 4.2 e 4.3, onde estão representados os sinais normalizados de um dos voluntários nos 3 eixos (x, y e z) e o vetor resultante correspondente. A Figura 4.1 apresenta os dados do acelerômetro, a Figura 5.2 apresenta os dados do giroscópio e, a Figura 5.3 apresenta os dados do magnetômetro, sendo que todos foram coletados pelo sensor IMU 1, localizado na região do terço distal do antebraço da mão dominante.



**Figura 4.1 -** Sinal do acelerômetro 1 de um dos voluntários. (a) sinal no eixo x, (b) sinal no eixo y, (c) sinal no eixo z e, (d) sinal resultante correspondente



**Figura 4.2 -** Sinal do giroscópio 1 de um dos voluntários. (a) sinal no eixo x, (b) sinal no eixo y, (c) sinal no eixo z e, (d) sinal resultante correspondente



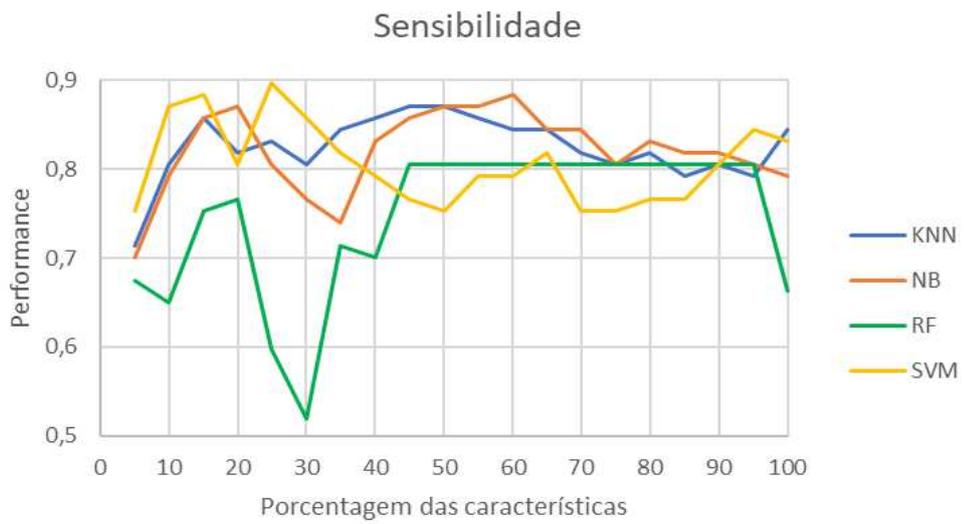
**Figura 4.3 - Sinal do magnetômetro 1 de um dos voluntários. (a) sinal no eixo x, (b) sinal no eixo y, (c) sinal no eixo z e, (d) sinal resultante correspondente**

A partir do sinal resultante, dado pelo valor de  $R$  (equação 3.1) subtraído da sua média, 324 características foram extraídas para cada um dos voluntários em cada uma das coletas.

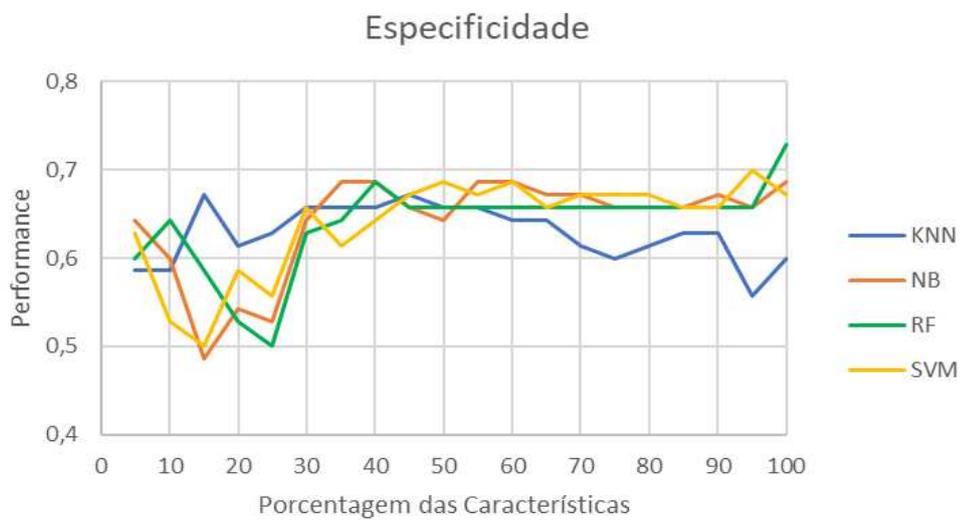
A partir de simulações para seleção dos parâmetros dos classificadores, temos que os melhores resultados encontrados foram:

- SVM: *Kernel* polinomial;
- KNN:  $k = 3$ ;
- RF: 120 árvores;
- NB: *Kernel (normal) predictor*.

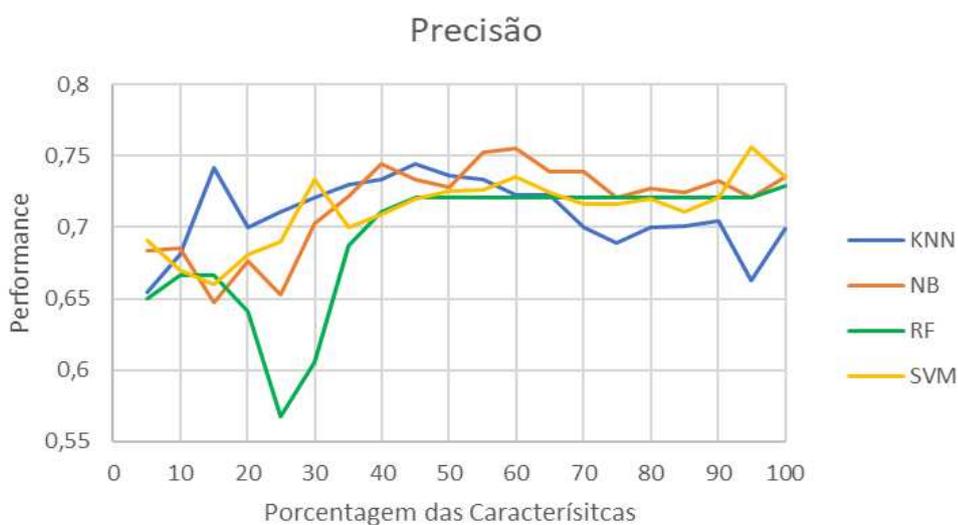
Os classificadores foram alimentados gradativamente com incrementos de 5% das características mais relevantes. As métricas foram calculadas para cada um dos classificadores separadas pelo percentual das características utilizadas. As Figuras 4.4, 4.5, 4.6 e 4.7 mostram os resultados calculados para a sensibilidade, especificidade, precisão e acurácia respectivamente.



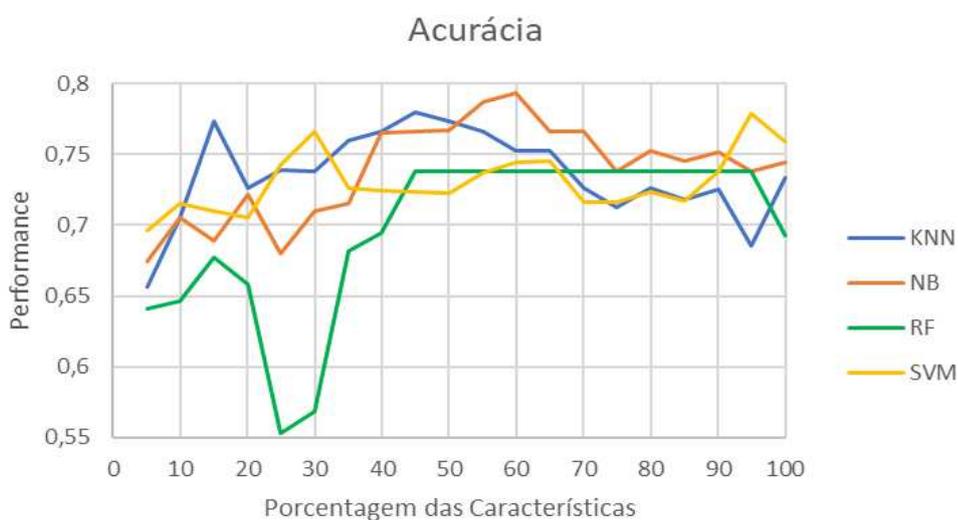
**Figura 4.4 - Sensibilidade dos classificadores em relação a porcentagem das características**



**Figura 4.5 - Especificidade dos classificadores em relação a porcentagem das características**



**Figura 4.6 - Precisão dos classificadores em relação a porcentagem das características**



**Figura 4.7 - Acurácia dos classificadores em relação a porcentagem das características**

Tendo em conta os dados apresentados nas Figuras 4.4, 4.5, 4.6 e 4.7, os melhores desempenhos para as métricas deram-se quando classificadores foram alimentados com 25%, 60% e 100% das características. Reunimos na Tabela 4.1 essas porcentagens que melhor obtiveram resultados para o cálculo das métricas, sendo que os maiores valores de cada métrica estão destacados em amarelo.

**Tabela 4.1 - Melhores resultados para as métricas dos classificadores**

25% das características					
Classificador	Métricas				Training accuracy
	Sensibilidade	Especificidade	Precisão	Acurácia	
KNN	0,831169	0,628571	0,711111	0,739452	0,628378
SVM	<b>0,896104</b>	0,557143	0,69	0,742655	0,675676
RF	0,597403	0,5	0,567901	0,553308	0,641892
NB	0,805195	0,528571	0,652632	0,679967	0,682432
60% das características					
Classificador	Métricas				Training accuracy
	Sensibilidade	Especificidade	Precisão	Acurácia	
KNN	0,844156	0,642857	0,722222	0,753027	0,709459
SVM	0,792208	0,685714	0,73494	0,743998	0,736486
RF	0,805195	0,657143	0,72093	0,738171	0,635135
NB	0,883117	0,685714	<b>0,755556</b>	<b>0,793752</b>	0,662162
100% das características					
Classificador	Métricas				Training accuracy
	Sensibilidade	Especificidade	Precisão	Acurácia	
KNN	0,844156	0,6	0,698925	0,733626	0,722973
SVM	0,831169	0,671429	0,735632	0,758854	0,695946
RF	0,662338	<b>0,728571</b>	0,728571	0,692322	0,648649
NB	0,792208	0,685714	0,73494	0,743998	0,662162

A partir da Tabela 4.1 temos que o classificador SVM foi o que obteve maior sensibilidade quando alimentado com 25% das características, enquanto que o classificador RF obteve melhor especificidade quando alimentado com todas as características e, o classificador NB obteve melhor precisão e acurácia quando alimentado com 60% das características.

As Tabelas 4.2, 4.3, 4.4, 4.5 e 4.6 relatam os pesos de cada parâmetro para classificação dos dados, sendo o peso de cada tarefa, cada IMU, cada sensor, das características e, das 18 características detalhadas, respectivamente.

**Tabela 4.2 - Peso de cada tarefa para classificação dos grupos**

		25%	60%
		%	%
<b>Tarefas</b>	TA	41,3	35,4
	TB	30	38,0
	TC	28,7	26,6
<b>Total</b>		100	100

TA – tarefa 1 (repouso), TB – tarefa 2 (pinça polpa a polpa), TC – tarefa 3 (supinação/pronação).

A partir da Tabela 4.2, têm-se que a tarefa 1 (repouso) obteve maior peso para diferenciar os grupos quando utilizadas 25% das características, diferente do que se observa com a classificação utilizando-se 60% das características, a qual a tarefa 2 (pinça polpa a polpa) obteve maior peso na discriminação dos grupos.

**Tabela 4.3 - Peso de cada IMU para classificação dos grupos**

		25%	60%
		%	%
<b>IMUs</b>	IMU1	32,5	45,8
	IMU2	67,5	54,2
<b>Total</b>		100	100

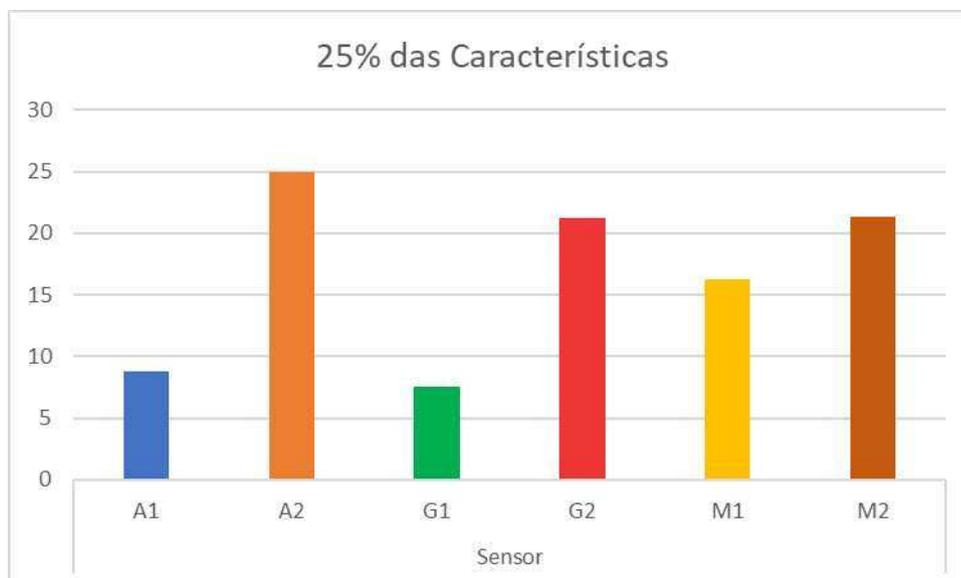
IMU1 – Unidade de medição inercial 1 (localizado na região do terço distal do antebraço da mão dominante), IMU2 – Unidade de medição inercial 2 (localizado no dorso da mão dominante).

**Tabela 4.4 - Peso de cada sensor para classificação dos grupos**

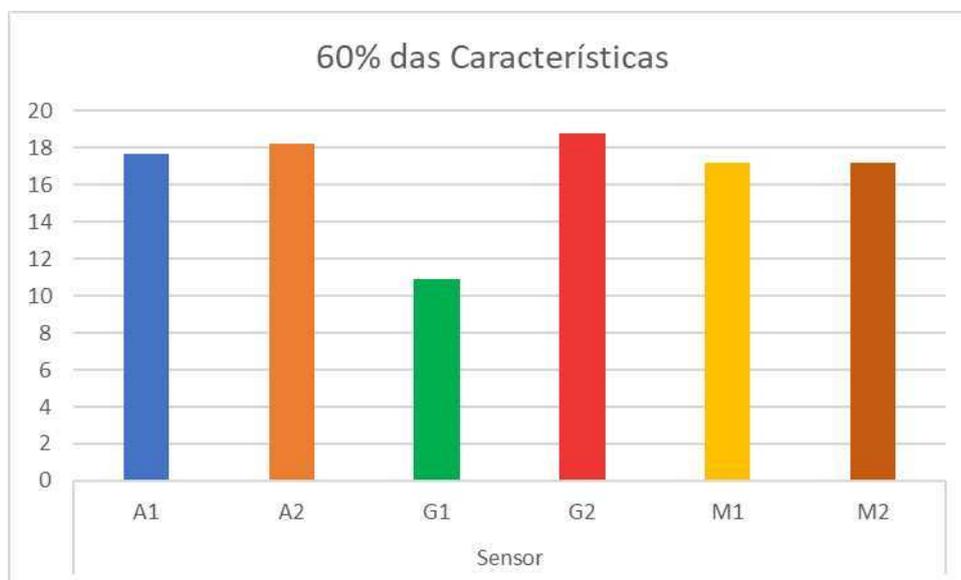
		25%	60%
		%	%
<b>Sensor</b>	A1	8,8	17,7
	A2	25,0	18,2
	G1	7,5	10,9
	G2	21,2	18,8
	M1	16,2	17,2
	M2	21,3	17,2
	<b>Total</b>	100	100

A1 – acelerômetro da IMU1, A2 – acelerômetro da IMU2, G1 – giroscópio da IMU1, G2 – giroscópio da IMU2, M1 – magnetômetro da IMU1, M2 – magnetômetro da IMU2.

Para melhor visualização, destacamos nas Figuras 4.8 e 4.9 os dados da Tabela 4.4.



**Figura 4.8 - Peso de cada um dos sensores quando os classificadores foram alimentados com 25% das características**



**Figura 4.9 - Peso de cada um dos sensores quando os classificadores foram alimentados com 60% das características**

Como pode ser observado nas Tabelas 4.3 e 4.4 e Figuras 4.8 e 4.9 relativas as IMUs e sensores, tanto a classificação utilizando-se 25% quanto com 60% das características, a

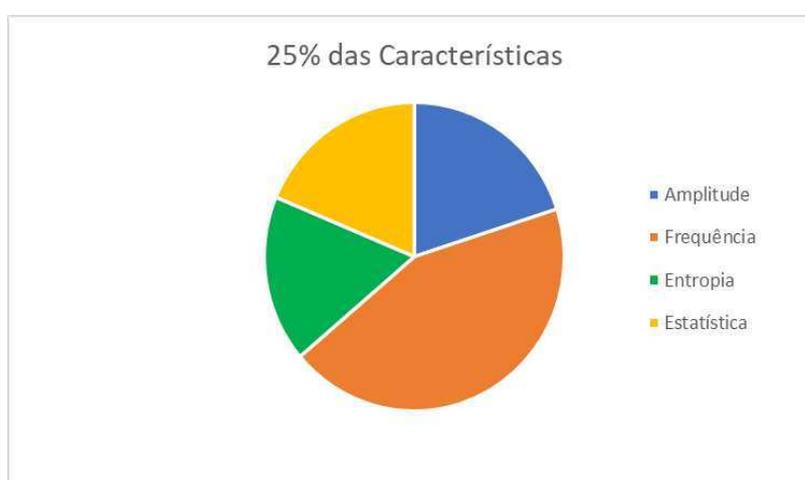
localização do sensor na região do dorso mão dominante (IMU2) obteve maior peso na discriminação dos grupos, consequentemente, os sensores da IMU2 tiveram uma influência maior na classificação, sendo que o acelerômetro teve maior peso quando alimentado com 25% das características e o giroscópio quando alimentado com 60% das características.

**Tabela 4.5 - Peso das características para a classificação dos grupos**

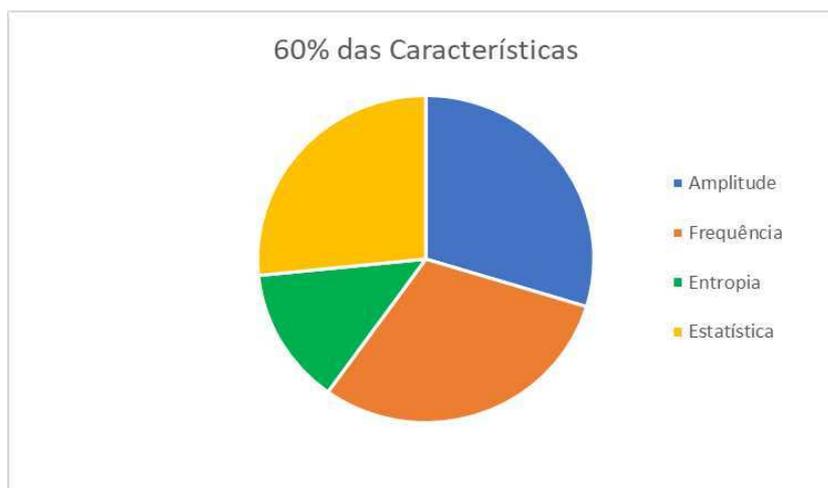
		25%	60%
		%	%
<b>Características</b>	Amplitude	20,0	29,7
	Frequência	43,8	30,2
	Entropia	17,5	13,5
	Estatística*	18,7	26,6
<b>Total</b>		100	100

\*Estatística – características relacionadas com a variabilidade e distribuição de dados.

As Figuras 4.10 e 4.11 destacam os dados referente à Tabela 4.5.



**Figura 4.10 - Peso do grupo de características quando os classificadores foram alimentados com 25% das características**



**Figura 4.11 - Peso do grupo de características quando os classificadores foram alimentados com 60% das características**

Diante da Tabela 4.5 e Figuras 4.10 e 4.11, temos que as características relacionadas à frequência obtiveram maior peso na classificação dos dados (43.8% quando alimentados 25% das características e, 30.2% quando alimentados com 60% das características), seguido das características relacionadas à amplitude (20% quando alimentados com 25% das características e, 29.7% quando alimentados com 60% das características), características relacionadas à estatística (18.7% quando alimentados com 25% das características e, 26.6% quando alimentados com 60% das características) e, por último as relacionadas à entropia (17.5% quando alimentados com 25% das características e, 13.5% quando alimentados com 60% das características).

A Tabela 4.6 mostra detalhadamente as características utilizadas neste trabalho e suas respectivas porcentagens na classificação dos dados.

**Tabela 4.6 - Peso de cada característica para a classificação dos grupos**

(continua)

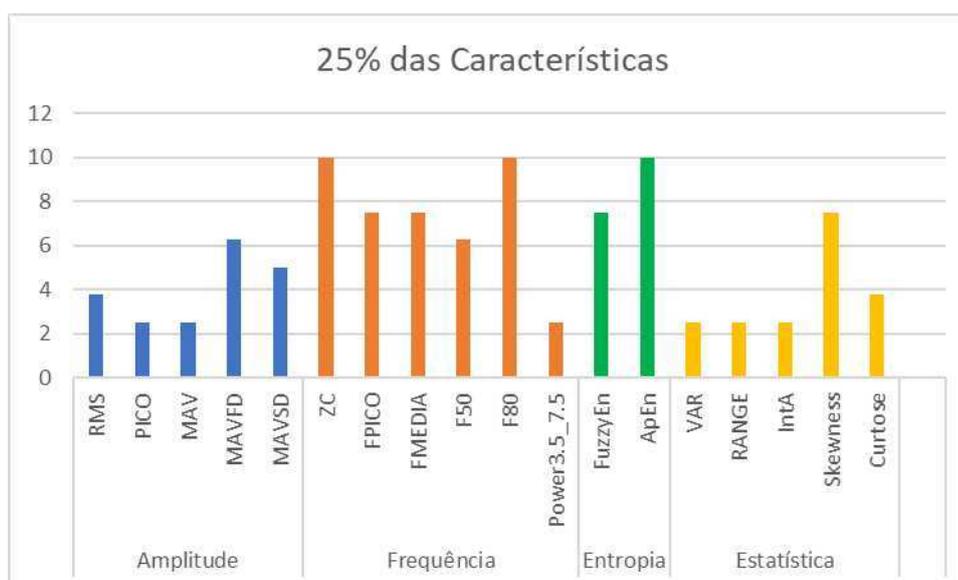
		25%	60%
		%	%
<b>Amplitude</b>	RMS	3,75	6,25
	PICO	2,5	4,68
	MAV	2,5	7,29
	MAVFD	6,25	5,72
	MAVSD	5	5,72

**Tabela 4.6 – Peso de cada característica para a classificação dos grupos.**

(conclusão)

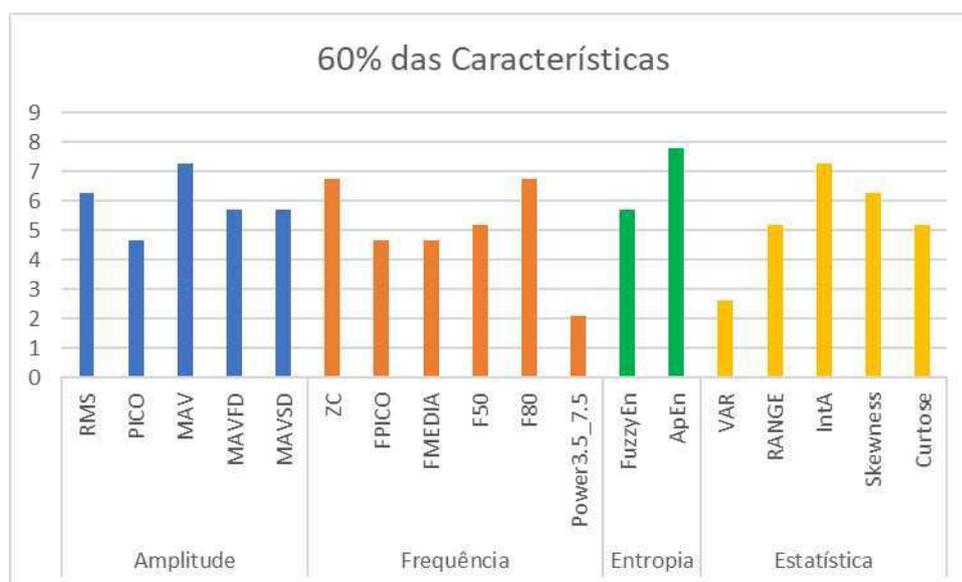
		25%	60%
		%	%
<b>Frequência</b>	ZC	10	6,77
	FPICO	7,5	4,68
	FMEDIA	7,5	4,68
	F50	6,25	5,2
	F80	10	6,77
	Power3.5_7.5	2,5	2,08
<b>Entropia</b>	<i>FuzzyEn</i>	7,5	5,72
	ApEn	10	7,81
<b>Estatística</b>	VAR	2,5	2,6
	RANGE	2,5	5,2
	IntA	2,5	7,29
	<i>Skewness</i>	7,5	6,25
	Curtose	3,75	5,2

Para melhor visualização dos dados da Tabela 4.6, apresentamos nas Figuras 4.12 e 4.13 o peso de cada uma das características quando os classificadores foram alimentados com 25% e 60% das características, respectivamente.



**Figura 4.12 - Peso de cada uma das características quando os classificadores foram alimentados com 25% das características**

A característica relacionada a amplitude que obteve maior peso para classificação dos dados foi MAVFD, com relação a frequência foram ZC e F80, já em relação a entropia dos dados a ApEn foi a que teve maior peso e, por fim, com relação a estatística a característica com maior peso foi a *Skewness*.



**Figura 4.13 - Peso de cada uma das características quando os classificadores foram alimentados com 60% das características**

Com relação à amplitude a característica MAV foi a que teve maior relevância para classificação dos dados, assim como para 25% das características, com relação a frequência, a ZC e F80 tiveram maior peso e em relação a entropia dos dados a ApEn também teve maior peso e, por fim, com relação a estatística a característica com maior peso foi a IntA.

No geral, as características com maiores relevâncias na discriminação dos grupos foram:

- Para 25% das características alimentando os classificadores: ZC, F80, ApEn, FPICO, FMEDIA, *FuzzyEn* e *Skewness*.

- Para 60% das características alimentando os classificadores: ApEn, MAV, IntA, ZC e F80.

# Capítulo 5

## DISCUSSÃO

---

Diante da mudança na estrutura etária da sociedade, em que a quantidade de indivíduos idosos está crescendo substancialmente, existem preocupações quanto às políticas públicas de saúde e econômica. De fato, tratando-se do Brasil onde a saúde é direito de todo cidadão e dever do estado (BRASIL, 1988), as medidas tomadas frente ao envelhecimento populacional são de extrema importância, de forma a garantir atendimento à saúde a todos, com qualidade e que visem diminuir a sobrecarga dos sistemas de saúde.

Ferramentas que auxiliem no apoio clínico, possibilitando complementar diagnósticos, otimizar tempo e recursos financeiros e, auxiliar na predição de fenótipos relacionados à idade e, conseqüentemente, no melhor entendimento sobre o processo de envelhecimento humano, são essenciais para garantir um atendimento eficiente.

Através da extração de características dos sinais de sensores inerciais de tarefas motoras, como por exemplo movimentos de pinça polpa a polpa e de supinação/pronação, os quais são bastante utilizados pelos profissionais da saúde para detecção ou evolução de patologias, os diagnósticos podem se tornar precoces e mais confiáveis, uma vez que complementar as avaliações clínicas com medidas quantitativas.

O sinal de sensores inerciais em grupos de diferentes faixas etárias, pode ser avaliado através de recursos relacionados à frequência, amplitude, distribuição dos dados, variabilidade e entropia, uma vez que as características biológicas do envelhecimento humano se manifestam principalmente através do movimento na forma de força, velocidade e sentido de vibração (CARMELI e colab., 2003). Neste estudo, foram selecionadas 18 características, sendo que 5 delas estão relacionadas à amplitude, 6 características relacionadas à frequência, 5 relacionadas à estatísticas (sendo 3 relacionadas à variabilidade do sinal e 2 relacionadas à distribuição dos dados) e 2 relacionadas à entropia do sinal. Para tanto, os sensores inerciais foram posicionados na região do terço distal do antebraço e no dorso da mão dominante, para

discriminar indivíduos adultos e idosos saudáveis a partir de diferentes algoritmos de classificação.

O sinal advindo de sensores inerciais combinado com técnicas de aprendizagem supervisionada, sobretudo os classificadores, auxilia na detecção precoce das alterações funcionais motoras relacionadas às mudanças biológicas devido ao avanço da idade (GOECKS e colab., 2020). Assim, enquanto os sensores inerciais quantificam e caracterizam os movimentos, os classificadores investigam e preveem as alterações motoras relacionadas à idade a partir das características extraídas pelos sensores.

Os métodos objetivos utilizados para quantificar e caracterizar tarefas motoras, e, prever eventos, tem sido amplamente utilizado no estudo de envelhecimento humano (ALIZADEH e colab., 2021; BEGG e colab., 2005; CUAYA-SIMBRO e colab., 2021; FUJIO e TAKEUCHI, 2021; FUKUCHI e colab., 2011; KALISCH e colab., 2006; KANEKO e colab., 2012; MANNINI e colab., 2016; RANGANATHAN e colab., 2001; TAREKEGN e colab., 2020; TAVAKOLAN e colab., 2011; WU e WANG, 2008).

O experimento realizado por *Kalisch e colaboradores* (2006) utilizou acelerômetros para comprovar o declínio do desempenho motor devido ao envelhecimento, relatando uma perda do domínio da mão dominante e um desempenho mais equitativo entre as duas mãos de idosos quando comparados a adultos jovens. *Kaneko e colaboradores* (2012) desenvolveram um sistema utilizando sensores inerciais com acelerômetros e giroscópios para diagnosticar deficiências de movimento, a partir de movimentos de supinação e pronação, obtendo como resultado curvas de envelhecimento da função neuromotora, sendo um potencial método para diagnóstico quantitativo.

O uso do algoritmo SVM para reconhecimento de padrões relacionados à idade tem se tornado cada vez mais frequente. O estudo de *Fukuchi e colaboradores* (2011) utilizou o classificador SVM para discriminar corredores adultos e idosos com base em dados cinemáticos de extremidades inferiores, alcançando 100% de taxa de desempenho de classificação, demonstrando alto potencial para reconhecimento de padrões relacionados à idade. *Tavakolan e colaboradores* (2011) utilizou o algoritmo SVM para classificar gestos manuais em grupos de idosos e adultos, obtendo uma média de classificação de 90.6% e 97.6% respectivamente. *Tarekegn e colaboradores* (2020) desenvolveu modelos preditivos para prever diferentes condições de fragilidade em idosos, sendo que, para mortalidade e internação urgente, o classificador SVM obteve melhores desempenhos quando comparados aos demais algoritmos de classificação. *Alizadeh e colaboradores* (2021) avaliou o desempenho dos classificadores SVM, KNN e RF para detecção de eventos de quedas em

idosos, constatando-se que o SVM obteve resultados mais adequados para distinguir de forma confiável o evento de queda, com precisão de 93% e especificidade entre 87% e 94%. Os estudos de *Begg e colaboradores (2005)*, *Mannini e colaboradores (2016)* e *Wu e Wang (2008)* relataram alto desempenho do classificador SVM no reconhecimento dos padrões de marcha em indivíduos adultos e idosos, os quais possibilitam detectar precocemente alterações da marcha, mostrando ser uma ferramenta eficaz em aplicações clínicas.

Dentre os algoritmos de classificação, outros modelos também se destacam na avaliação do envelhecimento humano. *Fujio e Takeuchi (2021)* investigou a performance do classificador RF para avaliar a influência do envelhecimento no controle postural, detectando altas taxas das métricas calculadas (sensibilidade: 94.4%, especificidade: 93.6% e precisão: 93.4%). *Cuaya-Simbro e colaboradores (2021)* avaliaram o desempenho de diferentes classificadores na previsão de quedas entre idosos com osteoporose e, como resultado, obtiveram que os classificadores KNN e RF foram os que obtiveram melhores desempenhos.

Analisando os estudos que retratam as alterações motoras ocasionadas devido ao avanço da idade, as alterações de marchas e controle postural estão em grande evidência (*ALIZADEH e colab., 2021*; *BEGG e colab., 2005*; *CUAYA-SIMBRO e colab., 2021*; *FUJIO e TAKEUCHI, 2021*; *FUKUCHI e colab., 2011*; *MANNINI e colab., 2016*; *WU e WANG, 2008*), todavia, os estudos que retratam as alterações manuais são escassos (*KALISCH e colab., 2006*; *KANEKO e colab., 2012*; *RANGANATHAN e colab., 2001*; *TAVAKOLAN e colab., 2011*).

Diante deste cenário, viu-se a necessidade de estudar a fundo as alterações manuais ocorridas diante do envelhecimento humano a partir de diferentes percepções.

Com intuito de obter respostas relacionadas ao tremor manual de forma mais realista, utilizou-se a abordagem em que o membro superior se encontrava sem nenhum apoio, pois segundo *Morrison e Newell (2012)* os ajustes posturais podem influenciar a dinâmica do tremor, dado que essas tarefas aumentam as demandas de controle do sistema neuromotor. Outro ponto relevante deste estudo a se destacar incluiu analisar diferentes tarefas manuais, utilizar sensores inerciais tridimensionais e posiciona-los em diferentes partes dos membros superiores dos voluntários, avaliar o peso de cada parâmetro na classificação dos grupos, além de incluir diferentes algoritmos de classificação da ML para detectar qual apresenta melhores resultados para este trabalho.

Para avaliar as alterações manuais ocorridas devido ao avanço da idade, nosso estudo utilizou diversos algoritmos de classificação para selecionar o modelo mais adequado na discriminação dos grupos (adultos e idosos). Diferentemente das técnicas abordadas nos

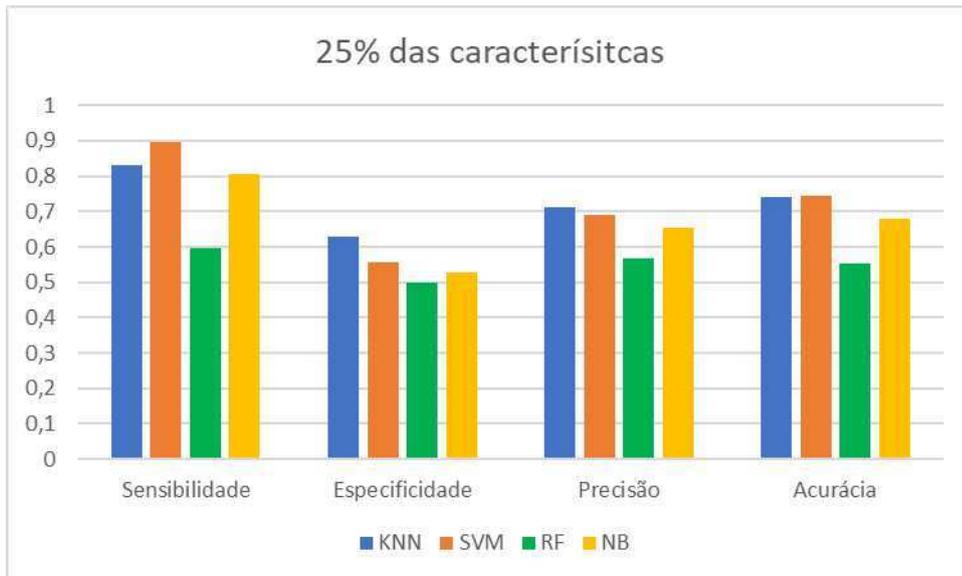
estudos aqui mencionados, a abordagem utilizando-se uma ampla variedade de características extraídas pelos sensores inerciais e a inclusão dessas características de forma gradual para alimentar os classificadores foi extremamente relevante para os achados deste estudo, sendo possível selecionar a melhor combinação para obter as melhores performances de cada algoritmo.

As características foram hierarquizadas de acordo com seu peso para a classificação dos grupos, calculadas através do pacote *CORElearn* e da função *attrEval* do *software* R. Assim, os classificadores foram alimentados gradativamente com 5% das características com maiores pesos, para avaliar qual ferramenta de classificação obteve melhores respostas na discriminação dos grupos.

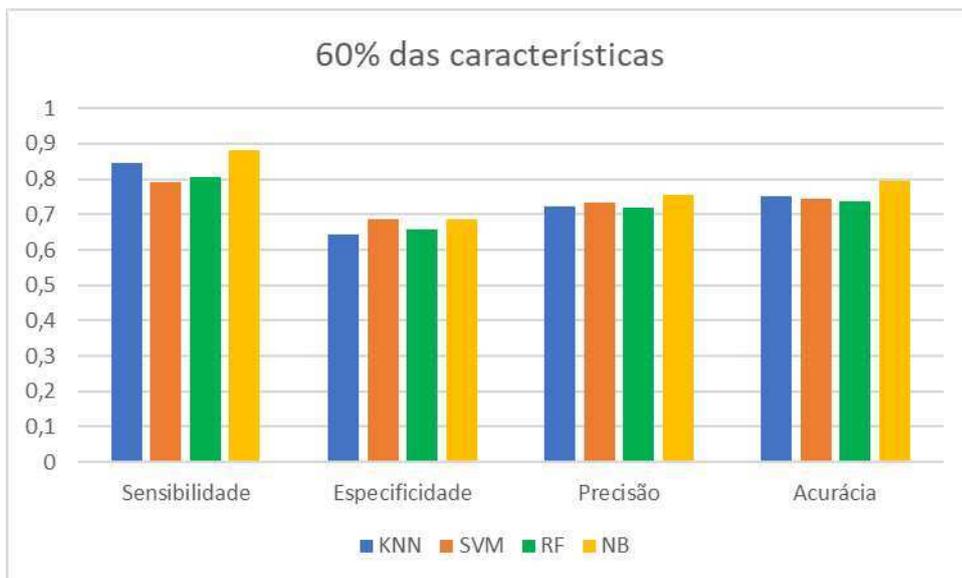
Foram comparados os classificadores KNN, SVM, RF e NB, os quais são utilizados como referência para esse tipo de classificação, sendo bastante utilizados hoje para prever eventos relacionadas à idade (ALIZADEH e colab., 2021; BEGG e colab., 2005; CUAYA-SIMBRO e colab., 2021; FUJIO e TAKEUCHI, 2021; FUKUCHI e colab., 2011; TAREKEGN e colab., 2020; TAVAKOLAN e colab., 2011; WU e WANG, 2008).

As métricas estatísticas utilizadas nesse trabalho relatam a capacidade de avaliação do desempenho dos classificadores. Nosso estudo analisou o comportamento dos classificadores em relação ao percentual das características utilizadas, obtendo melhores resultados quando alimentados com 25%, 60% e 100% das características. Pela Tabela 4.1 observa-se que a melhor sensibilidade encontrada foi para o classificador SVM (0,896104) quando alimentado com 25% das características, em relação a especificidade o classificador que obteve melhor desempenho foi o RF (0,728571) quando alimentado com todas as características e, o classificador NB foi o que obteve melhor precisão (0,755556) e acurácia (0,793752) quando alimentado com 60% das características.

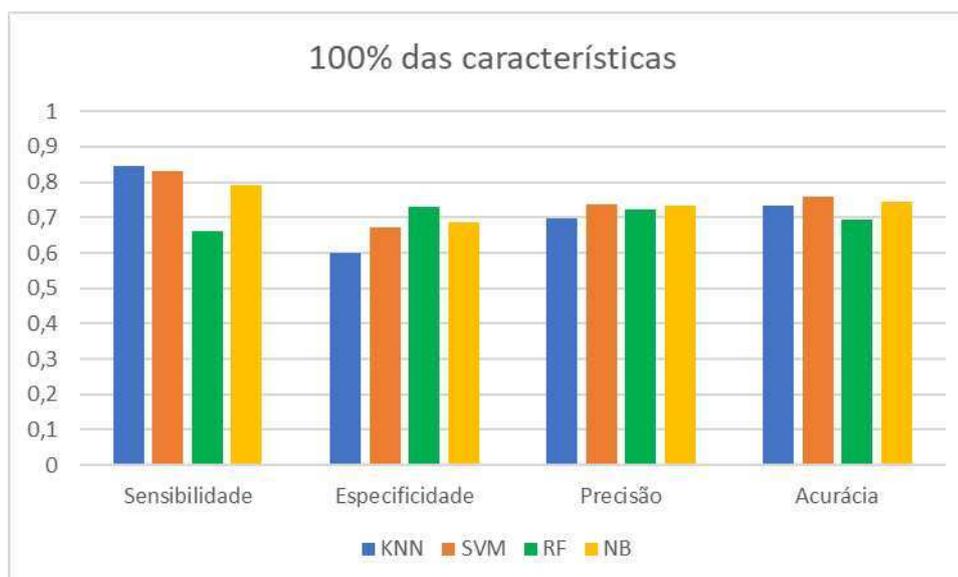
Para melhor visualização dos dados dispostos na Tabela 4.1 temos as Figuras 5.1, 5.2 e 5.3 que traz as métricas calculadas para cada porcentagem que obtiveram melhores resultados.



**Figura 5.1 - Métricas dos classificadores alimentados com 25% das características**



**Figura 5.2 - Métricas dos classificadores alimentados com 60% das características**



**Figura 5.3 - Métricas dos classificadores alimentados com 100% das características**

No geral, temos que as métricas calculadas para os classificadores alimentados com 60% e 100% das características foram bem semelhantes e tiveram melhores respostas quando comparados às métricas calculadas para os classificadores alimentados com 25% das características.

Para 25% das características, os classificadores KNN e SVM foram os que obtiveram melhores métricas e, o classificador RF obteve as piores métricas. Para 60% das características, o classificador NB obteve as melhores métricas e, os demais classificadores obtiveram performance semelhantes. Por fim, para 100% das características, com exceção dos classificadores RF e KNN que obtiveram piores performances para sensibilidade e especificidade respectivamente, as demais métricas tiveram resultados semelhantes para todos os classificadores.

Nosso estudo demonstrou concordância com os resultados obtidos em (ALIZADEH e colab., 2021; BEGG e colab., 2005; FUKUCHI e colab., 2011; MANNINI e colab., 2016; TAREKEGN e colab., 2020; TAVAKOLAN e colab., 2011; WU e WANG, 2008), relatando alto desempenho na classificação dos grupos a partir do classificador SVM, o qual obteve uma taxa de 89.6% quando utilizado 25% das características extraídas pelos sensores inerciais. Além disso, o resultado encontrado neste estudo relata altas taxas das demais métricas demonstrando a eficácia dos classificadores NB, RF e KNN, conforme (CUAYA-SIMBRO e colab., 2021; FUJIO e TAKEUCHI, 2021).

As altas taxas de sensibilidade calculadas demonstram a capacidade dos classificadores de classificar o grupo idoso corretamente. Assim, o sucesso na discriminação dos grupos sugere que os classificadores são capazes de prever alterações motoras relacionadas ao avanço da idade a partir da caracterização de tarefas motoras. Por isso, este estudo mostra a importância da metodologia no uso de amostras grandes para diferenciar adultos e idosos saudáveis, bem como sua capacidade de classificar alterações ocorridas devido ao envelhecimento.

As Tabelas 4.2, 4.3, 4.4 e 4.5 mostram que na classificação dos grupos quando alimentados com 25% das características, a tarefa que obteve maior influência na classificação foi a tarefa com o membro em repouso (TA), o acelerômetro localizado na região do dorso da mão dominante (A2) e as características relacionadas à frequência obtiveram maior importância para discriminação dos grupos. Já com os classificadores alimentados com 60% das características, as características relacionadas à frequência, o giroscópio localizado na região do dorso da mão dominante (G2) quando os voluntários realizaram a tarefa de pinça polpa a polpa (TB) possuíram maior peso para classificar os grupos, embora os acelerômetros e a tarefa de repouso também tenham tido um alto grau de importância para classificação dos grupos.

De fato, tratando-se de alterações biológicas relacionadas com o avanço da idade, em indivíduos idosos saudáveis a frequência do tremor fisiológico tende a ser maior devido principalmente ao declínio da capacidade funcional do sistema neuromuscular (MORRISON e NEWELL, 2012).

A Tabela 4.6 mostrou que as características com maiores relevâncias na discriminação dos grupos foram: para 25% das características alimentando os classificadores: ZC, F80, ApEn, FPICO, FMEDIA, *FuzzyEn* e *Skewness* e, para 60% das características alimentando os classificadores: ApEn, MAV, IntA, ZC e F80.

Embora as características relacionadas à entropia tenham tido uma menor porcentagem para classificação dos dados (Tabela 4.5), percebe-se pela Tabela 4.6 que as características ApEn e *FuzzyEn* tiveram grande relevância na classificação dos dados. Essa menor porcentagem é devido à menor quantidade de características relacionadas à entropia (apenas 2) quando comparadas com as demais (que utilizaram 6 características para frequência e 5 para amplitude e 5 para estatística).

A identificação de características com maiores relevâncias na discriminação de grupos de adultos e idosos é extremamente importante para entendimento do processo de envelhecimento humano. Segundo *Carmeli e colaboradores* (2003), os possíveis fatores

responsáveis pelo declínio da função motora das mãos em indivíduos idosos incluem doenças metabólicas e esqueléticas, como artrite reumatoide e osteoartrite, atrofia muscular devido à baixa ativação dos músculos da mão e, doenças neurodegenerativas, como doença de Parkinson. Dentre as patologias citadas, há uma restrição da amplitude do movimento, sobretudo, das mãos, punhos e dedos, além da dificuldade na execução de movimentos simples, com irregularidade, falta de coordenação e ou diminuição da velocidade do movimento (WERNER e colab., 2019). Assim, constata-se a importância de detectar características advindas de algumas tarefas motoras, a fim de auxiliar no diagnóstico de determinadas doenças, além de prever disfunções relacionadas ao envelhecimento humano.

Estudos como este demonstram a importância do uso de algoritmos de *machine learning* para investigar e prever as alterações motoras devido ao avanço da idade, uma vez que a detecção precoce dessas alterações pode oferecer uma vida mais longa, saudável e independente aos indivíduos idosos, além de ser uma ferramenta de apoio para tomada de decisões. Ainda, a investigação do peso das características na discriminação dos grupos pode auxiliar nas rotinas de avaliações clínicas, pois demonstram padrões diferentes entre os grupos e, assim, oferecem um maior embasamento ao profissional da saúde, facilitando a conduta a ser seguida.

# Capítulo 6

## CONCLUSÃO

---

Ao analisarmos os resultados encontrados, nosso estudo demonstra o peso de cada parâmetro para discriminação dos grupos, onde as tarefas de repouso (TA) e pinça polpa a polpa (TB), o sensor localizado no dorso da mão dominante dos voluntários (IMU2), sobretudo acelerômetro (A2) e giroscópio (G2), e as características relacionadas à frequência obtiveram maiores relevâncias. Os dados estatísticos encontrados neste estudo estão de acordo com a literatura, com destaque para o classificador SVM que obteve alta taxa de sensibilidade na discriminação dos grupos quando alimentado com 25% das características extraídas pelos sensores inerciais.

Uma vez que os classificadores são projetados para identificar padrões que sejam característicos de cada grupo, os resultados deste estudo permitiram verificar que, além das características relacionadas à frequência, o qual já era esperado devido a um aumento da frequência do tremor fisiológico diante do avanço da idade, características como *ApEn*, *FuzzyEn*, *IntA*, *MAV* e *Skewness*, são padrões que devem obter maior atenção na discriminação dos grupos adultos e idosos saudáveis.

Os resultados obtidos neste estudo a partir da abordagem experimental utilizada, que permitiu selecionar as melhores combinações de parâmetros para obter o melhor desempenho dos classificadores, sugere que o uso de algoritmos de classificação da *machine learning* na discriminação de grupos adultos e idosos saudáveis, com altas taxas de sensibilidades e especificidades, fornece informações valiosas para avaliações clínicas, uma vez que complementa os métodos subjetivos já utilizados, dando maior apoio nas tomadas de decisões.

Assim, o uso dos classificadores utilizados nesse estudo mostrou-se eficaz no auxílio da predição de características associadas ao envelhecimento, permitindo prever o risco de desenvolvimento de doenças e, conseqüentemente, orientando o planejamento do cuidado da

---

saúde. Além disso, esses classificadores podem também auxiliar no diagnóstico precoce de algumas doenças, uma vez que ao utilizar atributos relevantes relacionadas à idade, os classificadores aprendem a distinguir entre padrões normais e anormais dos dados.

# REFERÊNCIA

---

---

A. PHINYOMARK, S. HIRUNVIRIYA, C. Limsakul and P. Phukpattaranont. Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation. 2010, [S.l: s.n.], 2010. p. 856–860. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5491586&isnumber=5491394>>.

ALIZADEH, Jalal e colab. **Support Vector Machine Classifiers Show High Generalizability in Automatic Fall Detection in Older Adults**. *Sensors*, v. 21, n. 21, p. 7166, 28 Out 2021. <https://doi.org/10.3390/s21217166>

AMARAL, Josária F e colab. **Influence of aging on isometric muscle strength, fat-free mass and electromyographic signal power of the upper and lower limbs in women**. *Brazilian journal of physical therapy*, v. 18, n. 2, p. 183–90, 2014. <https://doi.org/10.1590/S1413-35552012005000145>

AMORIM, Fábio Ferreira e colab. **Avaliação de Tecnologias em Saúde: Contexto Histórico e Perspectivas**. *Com. Ciências Saúde*, v. 21, n. 4, p. 343–348, 2011.

ANTONELLI, Andrea e colab. **Comparison between the Airgo™ Device and a Metabolic Cart during Rest and Exercise**. *Sensors*, v. 20, n. 14, p. 3943, 15 Jul 2020. <https://doi.org/10.3390/s20143943>

AOKI, TOMOKO e FUKUOKA, YOSHIYUKI. **Finger Tapping Ability in Healthy Elderly and Young Adults**. *Medicine & Science in Sports & Exercise*, v. 42, n. 3, p. 449–455, Mar 2010. <https://doi.org/10.1249/MSS.0b013e3181b7f3e1>

BEGG, R.K. e PALANISWAMI, M. e OWEN, B. **Support Vector Machines for Automated Gait Classification**. *IEEE Transactions on Biomedical Engineering*, v. 52, n. 5, p. 828–838, Maio 2005. <https://doi.org/10.1109/TBME.2005.845241>

BERCHICCI, Marika e colab. **Prefrontal hyperactivity in older people during motor planning.** NeuroImage, v. 62, n. 3, p. 1750–1760, Set 2012. <https://doi.org/10.1016/j.neuroimage.2012.06.031>

BHATTACHARYA, Gautam e GHOSH, Koushik e CHOWDHURY, Ananda S. **An affinity-based new local distance function and similarity measure for kNN algorithm.** Pattern Recognition Letters, v. 33, n. 3, p. 356–363, Fev 2012. <https://doi.org/10.1016/j.patrec.2011.10.021>

BHIDAYASIRI, R. **Differential diagnosis of common tremor syndromes.** Postgraduate Medical Journal, v. 81, n. 962, p. 756–762, 1 Dez 2005. <https://doi.org/10.1136/pgmj.2005.032979>

BI, Qifang e colab. **What is Machine Learning? A Primer for the Epidemiologist.** American Journal of Epidemiology, 21 Out 2019. <https://doi.org/10.1093/aje/kwz189>

BLOOM, D.E. e LUCA, D.L. The Global Demography of Aging. [S.l: s.n.], 2016. p. 3–56. <https://doi.org/10.1016/bs.hespa.2016.06.002>

BORGES JUNIOR, Noé Gomes e colab. **Estudo comparativo da força de preensão isométrica máxima em diferentes modalidades esportivas.** Revista Brasileira de Cineantropometria e Desempenho Humano, v. 11, n. 3, 1 Jan 2011. <https://doi.org/10.5007/1980-0037.2009v11n3p292>

BOUROUHO, A. e colab. Comparison of classification methods to detect the Parkinson disease. Maio 2016, [S.l.]: IEEE, Maio 2016. p. 421–424. <https://doi.org/10.1109/EITech.2016.7519634>

BRASIL. **Art.196-200.** . Brasília/DF: [s.n.], 1988

BURR, Pierce e CHOUDHURY, Parichita. **Fine Motor Disability.** [S.l: s.n.], 2021. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/33085413>>.

BUTT, Abdul Haleem e colab. **Biomechanical parameter assessment for classification of**

**Parkinson's disease on clinical scale.** International Journal of Distributed Sensor Networks, v. 13, n. 5, p. 155014771770741, 5 Maio 2017. <https://doi.org/10.1177/1550147717707417>

CARMELI, Eli e PATISH, Hagar e COLEMAN, Raymond. **The Aging Hand.** The Journals of Gerontology: Series A, v. 58, n. 2, p. M146–M152, Fev 2003. <https://doi.org/10.1093/gerona/58.2.M146>

CARVALHO, José Alberto Magno De e GARCIA, Ricardo Alexandrino. **O envelhecimento da população brasileira: um enfoque demográfico.** Cadernos de Saúde Pública, v. 19, n. 3, p. 725–733, Jun 2003. <https://doi.org/10.1590/S0102-311X2003000300005>

CARVALHO FILHO, Eurico Thomaz De e PAPALÉO NETTO, Matheus. **Geriatrics: basis, clinics and therapeutics.** 2ª ed São Paulo (SP), p. 788, 2005.

CASTIGLIONI, Paolo e FAES, Luca e VALENZA, Gaetano. **Assessing Complexity in Physiological Systems through Biomedical Signals Analysis.** Entropy, v. 22, n. 9, p. 1005, 9 Set 2020. <https://doi.org/10.3390/e22091005>

CAVALHEIRO, Guilherme L e colab. **Study of age-related changes in postural control during quiet standing through Linear Discriminant Analysis.** BioMedical Engineering OnLine, v. 8, n. 1, p. 35, 18 Dez 2009. <https://doi.org/10.1186/1475-925X-8-35>

CELEBI, M. Emre e KINGRAVI, Hassan A. e VELA, Patricio A. **A comparative study of efficient initialization methods for the k-means clustering algorithm.** Expert Systems with Applications, v. 40, n. 1, p. 200–210, Jan 2013. <https://doi.org/10.1016/j.eswa.2012.07.021>

CHEN, Weiting e colab. **Characterization of Surface EMG Signal Based on Fuzzy Entropy.** IEEE Transactions on Neural Systems and Rehabilitation Engineering, v. 15, n. 2, p. 266–272, Jun 2007. <https://doi.org/10.1109/TNSRE.2007.897025>

COUSINS, M. **Temporal Measures of Human Finger Tapping: Effects of Age.** Pharmacology Biochemistry and Behavior, v. 59, n. 2, p. 445–449, Fev 1998. [https://doi.org/10.1016/S0091-3057\(97\)00443-7](https://doi.org/10.1016/S0091-3057(97)00443-7)

CUAYA-SIMBRO, German e colab. **Comparing Machine Learning Methods to Improve Fall Risk Detection in Elderly with Osteoporosis from Balance Data.** Journal of Healthcare Engineering, v. 2021, p. 1–11, 9 Set 2021. <https://doi.org/10.1155/2021/8697805>

DAI, Houde e LIN, Haijun e LUETH, Tim C. **Quantitative assessment of parkinsonian bradykinesia based on an inertial measurement unit.** BioMedical Engineering OnLine, v. 14, n. 1, p. 68, 12 Dez 2015. <https://doi.org/10.1186/s12938-015-0067-8>

DEUSCHL, Günther. Differential diagnosis of tremor. [S.l: s.n.], 1999. p. 211–220. [https://doi.org/10.1007/978-3-7091-6360-3\\_14](https://doi.org/10.1007/978-3-7091-6360-3_14)

DUIM, Etienne e colab. **Prevalência e características das feridas em pessoas idosas residentes na comunidade.** Revista da Escola de Enfermagem da USP, v. 49, n. spe, p. 51–57, Dez 2015. <https://doi.org/10.1590/S0080-623420150000700008>

ENGLEHART, K. e HUDGINS, B. **A robust, real-time control scheme for multifunction myoelectric control.** IEEE Transactions on Biomedical Engineering, v. 50, n. 7, p. 848–854, Jul 2003. <https://doi.org/10.1109/TBME.2003.813539>

FARIA, Alexandre Pereira De. **Sistema de captura de movimentos baseado em unidade de medida inercial.** Anais do VII EVINCI, v. 3, n. 2, p. 542–556, 2017.

FERNANDEZ-RUIZ, Juan e colab. **Age related prefrontal compensatory mechanisms for inhibitory control in the antisaccade task.** NeuroImage, v. 165, p. 92–101, Jan 2018. <https://doi.org/10.1016/j.neuroimage.2017.10.001>

FERNANDEZ, Hubert H. e GAALVEZ-JIMENEZ, Nestor e KHAN, Tarannum S. **Off spells and dyskinesias: Pharmacologic management of motor complications.** Cleveland Clinic Journal of Medicine, v. 79, n. 7 suppl 2, p. S8–S13, Jul 2012. <https://doi.org/10.3949/ccjm.79.s2a.02>

FERRI, Carlos Alexandre. **Rede de sensores inerciais e eletromiografia para análise da marcha humana.** 2017. 2017.

FROLOV, Nikita S. e colab. **Age-related slowing down in the motor initiation in elderly adults.** PLOS ONE, v. 15, n. 9, p. e0233942, 16 Set 2020. <https://doi.org/10.1371/journal.pone.0233942>

FUJIO, Kimiya e TAKEUCHI, Yahiko. **Discrimination of standing postures between young and elderly people based on center of pressure.** Scientific Reports, v. 11, n. 1, p. 195, 8 Dez 2021. <https://doi.org/10.1038/s41598-020-80717-z>

FUKUCHI, Reginaldo K. e colab. **Support vector machines for detecting age-related changes in running kinematics.** Journal of Biomechanics, v. 44, n. 3, p. 540–542, Fev 2011. <https://doi.org/10.1016/j.jbiomech.2010.09.031>

GOECKS, Jeremy e colab. **How Machine Learning Will Transform Biomedicine.** Cell, v. 181, n. 1, p. 92–101, Abr 2020. <https://doi.org/10.1016/j.cell.2020.03.022>

GONZALEZ, Sandy L. e ALVAREZ, Veronica e NELSON, Eliza L. **Do Gross and Fine Motor Skills Differentially Contribute to Language Outcomes? A Systematic Review.** Frontiers in Psychology, v. 10, 3 Dez 2019. <https://doi.org/10.3389/fpsyg.2019.02670>

GROSS, VOLKER e colab. **The Relationship between Normal Lung Sounds, Age, and Gender.** American Journal of Respiratory and Critical Care Medicine, v. 162, n. 3, p. 905–909, 1 Set 2000. <https://doi.org/10.1164/ajrccm.162.3.9905104>

GRUSS, Sascha e colab. **Pain Intensity Recognition Rates via Biopotential Feature Patterns with Support Vector Machines.** PLOS ONE, v. 10, n. 10, p. e0140330, 16 Out 2015. <https://doi.org/10.1371/journal.pone.0140330>

HANDELMAN, G. S. e colab. **eDoctor: machine learning and the future of medicine.** Journal of Internal Medicine, v. 284, n. 6, p. 603–619, Dez 2018. <https://doi.org/10.1111/joim.12822>

HASTIE, Trevor e TIBSHIRANI, Robert e FRIEDMAN, Jerome. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction.** 2 ed ed. [S.l.: s.n.], 2009. <https://doi.org/10.1007/978-0-387-84858-7>

HUANG, Norden E. e colab. **The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis**. Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences, v. 454, n. 1971, p. 903–995, 8 Mar 1998. <https://doi.org/10.1098/rspa.1998.0193>

JEON, Hyoseon e colab. **Automatic Classification of Tremor Severity in Parkinson's Disease Using a Wearable Device**. Sensors, v. 17, n. 9, p. 2067, 9 Set 2017. <https://doi.org/10.3390/s17092067>

JIMÉNEZ-JIMÉNEZ, Félix Javier e colab. **Influence of age and gender in motor performance in healthy subjects**. Journal of the Neurological Sciences, v. 302, n. 1–2, p. 72–80, Mar 2011. <https://doi.org/10.1016/j.jns.2010.11.021>

JUNG, Yong Gyu e KANG, Min Soo e HEO, Jun. **Clustering performance comparison using K -means and expectation maximization algorithms**. Biotechnology & Biotechnological Equipment, v. 28, n. sup1, p. S44–S48, 14 Nov 2014. <https://doi.org/10.1080/13102818.2014.949045>

KABIRAJ, Sajib e colab. Breast Cancer Risk Prediction using XGBoost and Random Forest Algorithm. Jul 2020, [S.l.]: IEEE, Jul 2020. p. 1–4. <https://doi.org/10.1109/ICCCNT49239.2020.9225451>

KALISCH, Tobias e colab. **Age-Related Attenuation of Dominant Hand Superiority**. PLoS ONE, v. 1, n. 1, p. e90, 20 Dez 2006. <https://doi.org/10.1371/journal.pone.0000090>

KANEKO, M. e colab. Aging curve of neuromotor function by pronation and supination of forearms using three-dimensional wireless acceleration and angular velocity sensors. Ago 2012, [S.l.]: IEEE, Ago 2012. p. 4676–4679. <https://doi.org/10.1109/EMBC.2012.6347010>

KHALILI, Z. e MORADI, M. H. Emotion recognition system using brain and peripheral signals: Using correlation dimension to improve the results of EEG. Jun 2009, [S.l.]: IEEE, Jun 2009. p. 1571–1575. <https://doi.org/10.1109/IJCNN.2009.5178854>

KHANAM, Farzana e AHMAD, Mohiuddin. Frequency based EMG power spectrum analysis

of Salat associated muscle contraction. Nov 2015, [S.l.]: IEEE, Nov 2015. p. 161–164. <https://doi.org/10.1109/CEEE.2015.7428245>

KHOURY, Nicolas e colab. **Data-Driven Based Approach to Aid Parkinson's Disease Diagnosis**. *Sensors*, v. 19, n. 2, p. 242, 10 Jan 2019. <https://doi.org/10.3390/s19020242>

LACREUSE, Agnès e ESPINOSA, Paola M. e HERNDON, James G. **Relationships among cognitive function, fine motor speed and age in the rhesus monkey**. *AGE*, v. 28, n. 3, p. 255–264, 14 Dez 2006. <https://doi.org/10.1007/s11357-006-9019-3>

MACIA, Enguerran e CHEVÉ, Dominique e MONTEPARE, Joann M. **Demographic aging and biopower**. *Journal of Aging Studies*, v. 51, p. 100820, Dez 2019. <https://doi.org/10.1016/j.jaging.2019.100820>

MANNINI, Andrea e colab. **A Machine Learning Framework for Gait Classification Using Inertial Sensors: Application to Elderly, Post-Stroke and Huntington's Disease Patients**. *Sensors*, v. 16, n. 1, p. 134, 21 Jan 2016. <https://doi.org/10.3390/s16010134>

MARTIN, Linda G. *Demography and Aging*. *Handbook of Aging and the Social Sciences*. [S.l.]: Elsevier, 2011. p. 33–45. <https://doi.org/10.1016/B978-0-12-380880-6.00003-4>

MCDONALD, Alison C. e MULLA, Daanish M. e KEIR, Peter J. **Using EMG Amplitude and Frequency to Calculate a Multimuscle Fatigue Score and Evaluate Global Shoulder Fatigue**. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, v. 61, n. 4, p. 526–536, 24 Jun 2019. <https://doi.org/10.1177/0018720818794604>

MEIER, Timothy B. e colab. **Support vector machine classification and characterization of age-related reorganization of functional brain networks**. *NeuroImage*, v. 60, n. 1, p. 601–613, Mar 2012. <https://doi.org/10.1016/j.neuroimage.2011.12.052>

MORRISON, S. e NEWELL, K. M. **Aging, Neuromuscular Decline, and the Change in Physiological and Behavioral Complexity of Upper-Limb Movement Dynamics**. *Journal of Aging Research*, v. 2012, p. 1–14, 2012. <https://doi.org/10.1155/2012/891218>

NATIONS, United. **World Population Prospects 2019**. Disponível em: <<https://population.un.org/wpp/Graphs/DemographicProfiles/Pyramid/900>>.

NUTT, John G. e colab. **Determinants of tapping speed in normal control subjects and subjects with Parkinson's disease: Differing effects of brief and continued practice**. *Movement Disorders*, v. 15, n. 5, p. 843–849, Set 2000. [https://doi.org/10.1002/1531-8257\(200009\)15:5<843::AID-MDS1013>3.0.CO;2-2](https://doi.org/10.1002/1531-8257(200009)15:5<843::AID-MDS1013>3.0.CO;2-2)

OLIVEIRA, Anderson Souza e colab. **The cognitive complexity of concurrent cognitive-motor tasks reveals age-related deficits in motor performance**. *Scientific Reports*, v. 8, n. 1, p. 6094, 17 Dez 2018. <https://doi.org/10.1038/s41598-018-24346-7>

PAPEGAAIJ, Selma e colab. **Aging causes a reorganization of cortical and spinal control of posture**. *Frontiers in Aging Neuroscience*, v. 6, 2014. <https://doi.org/10.3389/fnagi.2014.00028>

PEREIRA, Marcelo. **Acelerômetros**. Anuário da produção acadêmica docente, 2018.

PERES, Luciano e ANDRADE, Adriano. CLASSIFICAÇÃO A ATIVIDADE ELETROMIOGRÁFICA DO MÚSCULO ORBICULAR DA BOCA EM PACIENTES COM HANSENÍASE UTILIZANDO A MAQUINA VETORES DE SUPORTE. 27 Ago 2016, [S.l: s.n.], 27 Ago 2016. <https://doi.org/10.17648/seb-2016-53295>

PERES, Luciano Brinck e colab. **Discrimination between healthy and patients with Parkinson's disease from hand resting activity using inertial measurement unit**. *BioMedical Engineering OnLine*, v. 20, n. 1, p. 50, 22 Dez 2021. <https://doi.org/10.1186/s12938-021-00888-2>

PEREZ, Husein e TAH, Joseph H. M. **Improving the Accuracy of Convolutional Neural Networks by Identifying and Removing Outlier Images in Datasets Using t-SNE**. *Mathematics*, v. 8, n. 5, p. 662, 27 Abr 2020. <https://doi.org/10.3390/math8050662>

PETERSON, Anna D. e GHOSH, Arka P. e MAITRA, Ranjan. **Merging K -means with hierarchical clustering for identifying general-shaped groups**. *Stat*, v. 7, n. 1, p. e172,

2018. <https://doi.org/10.1002/sta4.172>

PINCUS, S M. **Approximate entropy as a measure of system complexity.** Proceedings of the National Academy of Sciences, v. 88, n. 6, p. 2297–2301, 15 Mar 1991. <https://doi.org/10.1073/pnas.88.6.2297>

QUANDT, Fanny e colab. **Spectral Variability in the Aged Brain during Fine Motor Control.** Frontiers in Aging Neuroscience, v. 8, 21 Dez 2016. <https://doi.org/10.3389/fnagi.2016.00305>

RAMOS, Camila. **Aprendizado de máquina como ferramenta para o prognóstico de pacientes em coma usando sinais eletroencefalográficos no espectro de 1 a 100 Hz.** 2022. Universidade Federal de Uberlândia, 2022. <http://doi.org/10.14393/ufu.te.2022.57>

RANGANATHAN, Vinoth K. e colab. **Effects of Aging on Hand Function.** Journal of the American Geriatrics Society, v. 49, n. 11, p. 1478–1484, 7 Nov 2001. <https://doi.org/10.1046/j.1532-5415.2001.4911240.x>.

RASHIDI, Hooman H. e colab. **Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods.** Academic Pathology, v. 6, p. 237428951987308, 1 Jan 2019. <https://doi.org/10.1177/2374289519873088>

RESIDENTE, Residente. **Medicina del deporte.** Acta Médica Colombiana, v. 43, n. 2S, p. 176, 24 Jun 2019. <https://doi.org/10.36104/amc.2018.1400>

RIBEIRO, L e PM, De e PEREIRA, A. **Analysis of the relationship between EEG signal and aging through Linear Discriminant Analysis (LDA).** Revista Brasileira de Engenharia Biomédica, 2012. Disponível em: <<http://rbejournal.org/doi/10.4322/rbeb.2012.023>>.

RIZON, M e MURUGAPPAN, M e NAGARAJAN, R. Feature Extraction Methods for Human Emotion Recognition using EEG: A Study. 2007, [S.l.: s.n.], 2007.

RUFF, Ronald M. e PARKER, Stephen B. **Gender- and Age-Specific Changes in Motor Speed and Eye-Hand Coordination in Adults: Normative Values for the Finger Tapping**

**and Grooved Pegboard Tests.** *Perceptual and Motor Skills*, v. 76, n. 3\_suppl, p. 1219–1230, 21 Jun 1993. <https://doi.org/10.2466/pms.1993.76.3c.1219>

RUIZ, Pedro J. Garcia e colab. **Capit timed tests quantify age-related motor decline in normal subjects.** *Journal of the Neurological Sciences*, v. 260, n. 1–2, p. 283–285, Set 2007. <https://doi.org/10.1016/j.jns.2007.04.034>

SKRZEK, Anna e colab. **Fine motor skills of the hands in Polish and Czech female senior citizens from different backgrounds.** *Aging Clinical and Experimental Research*, v. 27, n. 4, p. 491–498, 18 Ago 2015. <https://doi.org/10.1007/s40520-014-0299-7>

SMITH, C. D. e colab. **Critical decline in fine motor hand movements in human aging.** *Neurology*, v. 53, n. 7, p. 1458–1458, 22 Out 1999. <https://doi.org/10.1212/WNL.53.7.1458>

SOROND, Farzaneh A. e colab. **Aging, the Central Nervous System, and Mobility in Older Adults: Neural Mechanisms of Mobility Impairment.** *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, v. 70, n. 12, p. 1526–1532, Dez 2015. <https://doi.org/10.1093/gerona/glv130>

SOUBEYRAND, M. e colab. **Pronation and supination of the hand: Anatomy and biomechanics.** *Hand Surgery and Rehabilitation*, v. 36, n. 1, p. 2–11, Fev 2017. <https://doi.org/10.1016/j.hansur.2016.09.012>

STURMAN, Molly M. e VAILLANCOURT, David E. e CORCOS, Daniel M. **Effects of Aging on the Regularity of Physiological Tremor.** *Journal of Neurophysiology*, v. 93, n. 6, p. 3064–3074, Jun 2005. <https://doi.org/10.1152/jn.01218.2004>

TAREKEGN, Adane e colab. **Predictive Modeling for Frailty Conditions in Elderly People: Machine Learning Approaches.** *JMIR Medical Informatics*, v. 8, n. 6, p. e16678, 4 Jun 2020. <https://doi.org/10.2196/16678>

TAVAKOLAN, Mojgan e XIAO, Zhen Gang e MENON, Carlo. **A preliminary investigation assessing the viability of classifying hand postures in seniors.** *BioMedical Engineering OnLine*, v. 10, n. 1, p. 79, 9 Dez 2011. <https://doi.org/10.1186/1475-925X-10-79>

TÉRÉMETZ, Maxime e colab. **A novel method for the quantification of key components of manual dexterity after stroke.** Journal of NeuroEngineering and Rehabilitation, v. 12, n. 1, p. 64, 2 Dez 2015. <https://doi.org/10.1186/s12984-015-0054-0>

TESKEY, Wesley J. E. e ELHABIBY, Mohamed e EL-SHEIMY, Naser. **Inertial Sensing to Determine Movement Disorder Motion Present before and after Treatment.** Sensors, v. 12, n. 3, p. 3512–3527, 12 Mar 2012. <https://doi.org/10.3390/s120303512>

URBANOWICZ, Ryan J. e colab. **Relief-based feature selection: Introduction and review.** Journal of Biomedical Informatics, v. 85, p. 189–203, Set 2018. <https://doi.org/10.1016/j.jbi.2018.07.014>

VERVOORT, Danique e colab. **Multivariate Analyses and Classification of Inertial Sensor Data to Identify Aging Effects on the Timed-Up-and-Go Test.** PLOS ONE, v. 11, n. 6, p. e0155984, 6 Jun 2016. <https://doi.org/10.1371/journal.pone.0155984>

VOELCKER-REHAGE, Claudia. **Motor-skill learning in older adults—a review of studies on age-related differences.** European Review of Aging and Physical Activity, v. 5, n. 1, p. 5–16, 24 Abr 2008. <https://doi.org/10.1007/s11556-008-0030-9>

VOLPON, José B. **Semiologia Ortopédica.** Ribeirão Preto, 1996. , p. 67–79. <https://doi.org/10.11606/issn.2176-7262.v29i1p67-79>

VYZAS, Elias e PICARD, Rosalind W. **Affective Pattern Classification.** Emotional & Intelligent the Tangled Knot of Cognition, 1998. , p. 176–182.

WASSERMAN, Lary. **All of Statistics.** 1 ed ed. [S.l: s.n.], 2004. <https://doi.org/10.1007/978-0-387-21736-9>

WERNER, Emilio e BEREJUCK, Marcelo Daniel e BEZERRA, Poliana Penasso. **Utilização de sensores para a avaliação da Bradicinesia em Parkinsonianos.** Brazilian Journal of health Review, v. 2, n. 2, p. 2145–2157, 2019.

WHO. Active Ageing - A Policy Framework. 2015, [S.l: s.n.], 2015. p. 59.

WU, Jianning e WANG, Jue. **PCA-Based SVM for Automatic Recognition of Gait Patterns**. Journal of Applied Biomechanics, v. 24, n. 1, p. 83–87, Fev 2008. <https://doi.org/10.1123/jab.24.1.83>

ZARUZ, Maria Jose Ferreira. **CARACTERIZAÇÃO DE TAREFA MOTORA ESTÁTICA E CINÉTICA DE ANTEBRAÇO E MÃO EM INDIVÍDUOS HÍGIDOS**. 2016. 82 f. Universidade Federal de Uberlândia, 2016.

ZHANG, Yue e colab. **Research on GA-SVM Based Head-Motion Classification via Mechanomyography Feature Analysis**. Sensors, v. 19, n. 9, p. 1986, 28 Abr 2019. <https://doi.org/10.3390/s19091986>

ZHIBIN LIU e LI BAI. Evaluating the supplier cooperative design ability using a novel support vector machine algorithm. Abr 2008, [S.l.]: IEEE, Abr 2008. p. 986–989. [h//doi.org/10.1109/CSCWD.2008.4537113](https://doi.org/10.1109/CSCWD.2008.4537113)