

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Paulo Matheus Girardi**

**Identificação de atividades cotidianas  
com membros superiores através de  
sensores inerciais**



**Paulo Matheus Girardi**

**Identificação de atividades cotidianas  
com membros superiores através de  
sensores inerciais**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Processamento Digital de Sinais

Orientador: Prof. Dr. Samuel Lourenço Nogueira

São Carlos - SP

2023





**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

Centro de Ciências Exatas e de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

---

**Folha de Aprovação**

---

Defesa de Dissertação de Mestrado do candidato Paulo Matheus Girardi, realizada em 21/07/2023.

**Comissão Julgadora:**

Prof. Dr. Samuel Lourenço Nogueira (UFSCar)

Prof. Dr. Roberto Santos Inoue (UFSCar)

Prof. Dr. Wilian Miranda dos Santos (UNESP)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Elétrica.

*À minha querida mãe, Antonia Costa, e à minha amada esposa, Bruna Louise, por serem o meu sólido alicerce ao longo de toda construção deste projeto de pesquisa.*

---

# Agradecimentos

---

À Deus, pela graça da vida em toda sua plenitude.

Aos meus pais, Paulo Sergio e Antonia Costa, e irmão, João Lucas, com carinho e admiração pela compreensão e incansável apoio ao longo deste mestrado.

Aos familiares, Cidinha, José Roberto, Geni, Camila e Rose, pelo apoio e incentivo.

À minha amada esposa, Bruna, pelo amor, companheirismo, paciência, suporte e orientação durante esta jornada.

Em especial, ao Prof. Dr. Samuel Loureço Nogueira, pela confiança, orientação, paciência e tempo dedicado a este importante trabalho.

Aos professores e funcionários do Departamento de Engenharia Elétrica (DEE) e Engenharia Mecânica (DEMec) da UFSCar.

Aos amigos de pesquisa, Danilo Souza, Edson Francelino, Lucca Baldocchi, Mateus José, Simone Garcia, pelas contribuições acerca do desenvolvimento deste projeto.

Aos queridos professores e amigos, Profa. Dra. Luiza Helena e Prof. Dr. Marcelo Azevedo, pelo apoio, confiança e incentivo à pesquisa brasileira.

Aos meus primos, Heitor Marconato e Prof. Dr. André Marconato pela contribuição durante toda a fase de seleção do mestrado.

Aos caros amigos, Adalberto, Angelelli, Antoniassi, Armando, Barufaldi, Basanela, David, Tolesani e Matheus Zuin, por alegrar meus dias e manter a minha fé.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Fundação de Amparo à Pesquisa de São Paulo (FAPESP) pelo fomento de bolsas de pesquisa e investimentos, que permitiram minha dedicação e execução deste trabalho.

Aos membros e conselheiros do CCET e PPGE da UFSCar, cujas orientações e normativas de regimento contribuíram para o desenvolvimento desta pesquisa.





*“Cada pessoa deve trabalhar para o seu aperfeiçoamento e, ao mesmo tempo,  
participar da responsabilidade coletiva por toda a humanidade.”*  
*(Marie Curie)*



---

# Resumo

---

Foi proposto neste trabalho o desenvolvimento de estratégias e metodologias de processamento de dados para identificação de 7 atividades cotidianas exercidas com membros superiores, com apoio de sensores inerciais e técnicas de aprendizado de máquina. Para isto, foram utilizados métodos computacionais para tratamento de dados, tais como, síntese dos dados para homogeneização do número de amostras, banco de filtros digitais, janelamento de Hamming, extração de atributos e classificação por rede neural com a *toolbox* do Matlab *Neural Net Pattern Recognition*. Neste estudo, foram utilizadas duas unidades de medição inercial, uma em cada pulso. Tal escolha foi tomada, uma vez que boa parte das atividades realizadas exige cooperação entre os dois membros. Assim, através de treinamento supervisionado das redes neurais, obteve-se acurácia média superior a 90% para identificação das atividades, o que demonstra a viabilidade das estratégias propostas para identificação de atividades diárias com membros superiores.

**Palavras-chave:** Membros Superiores. Identificação de Atividades. Rede Neural Artificial. Sensores Inerciais.



---

# Abstract

---

In this work, the development of data processing strategies and methodologies for identifying 7 everyday activities performed with the upper limbs was proposed, with the support of inertial sensors and machine learning techniques. Computational methods were used for data processing, including data synthesis to homogenize the number of samples, digital filter bank, Hamming windowing, feature extraction, and classification using a neural network with the Matlab Neural Net Pattern Recognition toolbox. In this study, two units of inertial measurement were used, one on each wrist. This choice was made because a significant portion of the performed activities requires cooperation between the two limbs. Thus, through supervised training of the neural networks, an average accuracy of over 90% was achieved for activity identification, demonstrating the feasibility of the proposed strategies for identifying daily activities involving the upper limbs.

**Keywords:** Upper Limbs. Activity Recognition. Artificial Neural Network. Inertial Sensors.



---

# Lista de ilustrações

---

Figura 1 – Taxa de incapacidade global ocasionadas por diferentes distúrbios neurológicos. . . . .	25
Figura 2 – Previsão de retorno financeiro após investimento. . . . .	26
Figura 3 – Ambiente da coleta . . . . .	34
Figura 4 – Posicionamento da camera . . . . .	34
Figura 5 – Dados inerciais fornecidos pelas IMUs . . . . .	35
Figura 7 – Hamming genérico . . . . .	40
Figura 8 – Sinal do giroscópio do membro dominante recortado em 10s . . . . .	41
Figura 9 – Janelamento de Hamming aplicado ponto a ponto no recorte . . . . .	41
Figura 10 – Modelo básico de um classificador k-NN. . . . .	43
Figura 11 – Modelo de uma Rede Neural Artificial. . . . .	44
Figura 12 – Representação das atividades nos 3 ciclos de repetição. . . . .	48
Figura 13 – Transmissão de dados. . . . .	48
Figura 14 – Posicionamento dos sensores. . . . .	49
Figura 15 – Interface do aplicativo <i>BSL Capture</i> . . . . .	50
Figura 16 – Sincronização do tempo do vídeo com o tempo do sensor . . . . .	51
Figura 17 – Análise visual da coleta de dados . . . . .	51
Figura 18 – Topologia da Rede Neural de Reconhecimento de Padrões utilizada. . . . .	54
Figura 19 – Teste k-NN1 . . . . .	57
Figura 20 – Teste k-NN 5 . . . . .	58
Figura 21 – Teste NNPR2 . . . . .	60
Figura 22 – Teste NNPR3 . . . . .	61
Figura 23 – Câmera utilizada para análise visual. . . . .	73
Figura 24 – Sensores WitMotion. . . . .	75
Figura 25 – Protocolo de verificação pré-coleta. . . . .	78
Figura 26 – Sequência para configuração do aplicativo . . . . .	79
Figura 27 – Servidor em nuvem com os arquivos das coletas enviados pelo aplicativo. . . . .	81





---

## Lista de tabelas

---

Tabela 1 – Protocolo de atividades MAL-45. . . . .	32
Tabela 2 – Definição das atividades de membros superiores . . . . .	33
Tabela 3 – Abordagens metodológicas utilizadas em estudos correlatos. . . . .	37
Tabela 4 – Assimetria quantitativa amostral dos dados originais . . . . .	39
Tabela 5 – Assimetria quantitativa amostral após aumento dos dados . . . . .	39
Tabela 6 – Técnicas de aprendizado de máquina utilizadas em trabalhos similares. . . . .	42
Tabela 7 – Quantidade de atributos extraídos do sinal . . . . .	52
Tabela 8 – Todos os atributos utilizados no classificador <i>fine k-NN</i> . . . . .	53
Tabela 9 – Testes realizados com <i>Fine k-NN</i> . . . . .	56
Tabela 10 – Testes realizados com <i>Neural Net Pattern Recognition</i> (Rede Neural de Reconhecimento de Padrões) (NNPR) . . . . .	59
Tabela 11 – Endereçamento local dos sensores. . . . .	75
Tabela 12 – Configurações do fabricante. . . . .	76



---

# Lista de siglas

---

**AVC** Acidente Vascular Cerebral

**AMS** Atividades de Membros Superiores

**BPNN** *Backpropagation Neural Net* (Rede Neural com Retropropagação)

**DT** *Decision Trees* (Árvores de Decisão)

**FFT** *Fast Fourier Transform* (Transformada Rápida de Fourier)

**FTP** *File Transfer Protocol* (Protocolo de Transferência de Arquivos)

**GRNN** *General Regression Neural Network* (Rede Neural de Regressão Genérica)

**GMM** *Gaussian Mixed Model* (Modelo Misto Gaussiano)

**IMUs** *Inertial Measurement Units* (Unidades de Medição Inercial)

**k-NN** *k-Nearest Neighbours* (k Vizinhos mais próximos)

**LR** *Logistic Regression* (Regressão Logística)

**MI**s *Membros Inferiores*

**ML** *Machine Learning* (Aprendizado de Máquina)

**MAL** *Motor Activity Log* (Registro de Atividade Motora)

**NNPR** *Neural Net Pattern Recognition* (Rede Neural de Reconhecimento de Padrões)

**PCA** *Principal Component Analysis* (Análise de Componentes Principais)

**RMS** *Root Mean Square* (Raíz Quadrada da Média)

**RNAs** *Redes Neurais Artificiais*

**RBF** *Radial Basis Function* (Função de Base Radial)

**SEEGs** *Sensores Eletroencefálicos*

**SEMGs** *Sensores Eletromiográficos*

**SVM** *Support Vector Machine* (Máquina de Vetores de Suporte)

**SCN** *Stochastic Configuration Network* (Rede de Configuração Estocástica)

**TA** *Tecnologia Assistiva*

**UWB** *Ultra-Wideband* (Banda Ultra Larga)

---

# Lista de símbolos

---

$g$	Aceleração da gravidade
$x_n$	Amostra de treinamento posicionada em $n$
$\phi$	Ângulo de rotação do eixo $x$
$\theta$	Ângulo de rotação do eixo $y$
$\psi$	Ângulo de rotação do eixo $z$
$\omega_n$	Classe da amostra de treinamento posicionada em $n$
$FS$	Frequência de amostragem
$S_i$	Matriz de dados do sensor inercial
$M_x$	Matriz de rotação do eixo $x$
$M_y$	Matriz de rotação do eixo $y$
$M_z$	Matriz de rotação do eixo $z$
$m$	Prefixo Mili equivalente a $10^{-3}$
$N$	Número total de amostras
$c$	Número total de classes
$k$	Número de vizinhos mais próximos utilizados pelo classificador k-NN
$\omega(n)$	Valor da janela de Hamming aplicada no instante $n$



---

# Sumário

---

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>23</b>
1.1	Movimento e mobilidade humana . . . . .	23
1.2	Tecnologias assistivas e monitoramento . . . . .	25
1.3	Objetivos . . . . .	28
1.4	Organização do texto . . . . .	29
<b>2</b>	<b>METODOLOGIA . . . . .</b>	<b>31</b>
2.1	Atividades de membros superiores . . . . .	31
2.2	Ambiente controlado . . . . .	33
2.3	Sensores inerciais e identificação de atividades . . . . .	34
2.4	Pré-Processamento . . . . .	35
2.4.1	Extração de atributos . . . . .	36
2.4.2	Aumento do número de dados . . . . .	37
2.4.3	Janelamento de Hamming . . . . .	39
2.5	Algoritmos de classificação . . . . .	40
2.5.1	k-Nearest Neighbors . . . . .	41
2.5.2	Redes Neurais Artificiais . . . . .	43
<b>3</b>	<b>DESENVOLVIMENTO . . . . .</b>	<b>47</b>
3.1	Representação experimental . . . . .	47
3.2	Plataforma de aquisição e transmissão de dados . . . . .	47
3.3	Pré-processamento e extração de características . . . . .	50
3.3.1	Sincronização do vídeo e sensores . . . . .	50
3.3.2	Sintetização dos dados . . . . .	52
3.3.3	Rede Neural por Reconhecimento de Padrões . . . . .	53
<b>4</b>	<b>RESULTADOS . . . . .</b>	<b>55</b>

4.1	Fine k-Nearest Neighbors . . . . .	55
4.2	Neural Nets Pattern Recognition (NNPR) . . . . .	58
5	CONCLUSÃO . . . . .	63
	REFERÊNCIAS . . . . .	65
APÊNDICE A	CÂMERA DE VÍDEO . . . . .	73
APÊNDICE B	SENSORES INERCIAIS . . . . .	75
APÊNDICE C	LISTA DE VERIFICAÇÃO . . . . .	77
APÊNDICE D	APLICATIVO E SERVIDOR FTP . . . . .	79



---

# Capítulo 1

## Introdução

---

### 1.1 Movimento e mobilidade humana

O movimento humano é essencial para a nossa sobrevivência e participação social. Os primeiros estudos que analisam mais a fundo as articulações humanas são datadas de 1680 e pertencem à Giovanni Alfonso Borelli, no estudo Thurston (1999) ele é descrito como “Pai da Biomecânica Moderna” por se tratar de um dos pioneiros desta área de estudo. Neste período, iniciou-se as bases de estudo acerca da biomecânica, com aplicações em ciências esportivas, ortopedia, robótica, locomoção animal, fisiologia e biologia evolutiva. Atualmente elas englobam diversas áreas de estudos, como saúde (ZHOU et al., 2020), esportes (ERMES et al., 2008), trabalho (TAO et al., 2018). Tais estudos demonstram que o reconhecimento destas atividades possui vasta aplicabilidade, permitindo que esta identificação seja utilizada durante o processo de reabilitação.

Para isto, sensores são empregados para a captação dos dados dos movimentos realizados e as classificações destas atividades são feitas por meio de algoritmos de processamento de dados, implementados com apoio de *softwares* específicos, como por exemplo, o Matlab. Assim, estudos desenvolvidos ilustram a fidedignidade e acurácia das classificações, cujos resultados corroboram para validar as técnicas computacionais utilizadas, bem como as metodologias empregadas, similarmente como desenvolvido em Majumder e Kehtarnavaz (2021), ademais, os avanços destes monitoramentos quando destinados à reabilitação, tal como nos estudos de Bratan e Clarke (2006), Martins et al. (2012) e Martins et al. (2015).

Aplicado à reabilitação, na área da saúde, o monitoramento de atividades tem sido uma área de grande interesse e avanço nos últimos anos, especialmente para reabilitação de pacientes pós-Acidente Vascular Cerebral (AVC) (LUM et al., 1999; RICHARDS et al.,

2008; MILLER et al., 2020). Estudos recentes apresentam diversas técnicas e tecnologias que têm se mostrado promissoras para auxiliar na avaliação e acompanhamento de pacientes durante a reabilitação, permitindo uma abordagem mais precisa e individualizada, (PANWAR et al., 2019; CHAE et al., 2020).

No início dos anos 80, os autores Ramey e Yang (1981) analisaram quantitativamente o movimento humano durante atividades que exigiram grande esforço muscular, tais como esportes e danças, onde foram realizadas simulações com o intuito de aperfeiçoar o desempenho dos atletas e competidores. Em outro momento, Hatze (1984) realizou um estudo semelhante aplicando análise quantitativa no movimento humano além de utilizar estratégias de controle neural para otimizar estes movimentos.

Por outro lado, em 1986, o estudo Daley, Mayo e Wood-Dauphinée (1999), no qual, os membros do Hospital de Recuperação Judaica compostos por médicos e pesquisadores, trabalharam no desenvolvimento de um procedimento de avaliação motora em pacientes Pós-AVC, que consistia em avaliar os movimentos, a coordenação motora e a mobilidade básica dos pacientes como indicador de avanço da reabilitação motora.


O AVC, é uma condição grave e potencialmente fatal que afeta o cérebro, resultando em uma interrupção crítica do fluxo sanguíneo para determinadas áreas cerebrais. Essa interrupção pode levar à morte de células nervosas na região afetada, causando danos neurológicos significativos.

Existem dois principais tipos de AVC, cada um com suas características distintas. O AVC isquêmico ocorre quando um coágulo sanguíneo ou uma placa de gordura se forma dentro de uma artéria no cérebro, obstruindo o fluxo sanguíneo e privando as células cerebrais de oxigênio e nutrientes essenciais. Em contrapartida, o AVC hemorrágico é resultado do rompimento de um vaso sanguíneo no cérebro, o que leva ao sangramento na região cerebral afetada, aumentando a pressão intracraniana e causando danos pela compressão das estruturas neurais.

Fatores pelos quais são responsáveis pela morte das células nervosas na região afetada, conseqüentemente, a parte lesionada do cérebro não consegue emitir comandos específicos, os quais geram perdas e limitações de movimentos que podem levar o paciente a desenvolver certas deficiências motoras devido a estes seguimentos afetados, estabelecendo ao enfermo uma incapacidade funcional (ALARCÓN et al., 2004).

O estudo proposto por Duncan et al. (2005) apontou na época que cerca de 40% dos pacientes Pós-AVC possuíam algum tipo de restrição motora, sendo desejável fornecer ao paciente a possibilidade de retorno às suas atividades básicas diárias, através de sua reabilitação motora. Recentemente, entre os anos de 1990 à 2019, os autores Feigin et al. (2021) realizaram um grande estudo ao redor do mundo acerca de diversas doenças neurológicas e suas provenientes restrições por incapacidade motora, na qual 42% destas eram decorrentes de AVC, como pode ser visto na Figura 1.

Figura 1 – Taxa de incapacidade global ocasionadas por diferentes distúrbios neurológicos.



Fonte: Adaptada de Feigin et al. (2020).

No Brasil, segundo Bensenor et al. (2015), em estudo realizado em 2015, estimou-se que 2.231.000 pessoas sofreram AVC. Deste total, 568.000 tiveram incapacidade motora grave. Em 2019, o número total de óbitos por AVC no Brasil, foi de 101.965; passando para 102.812, em 2020; e 84.426, de janeiro a 27 de outubro de 2021, segundo dados fornecidos por Academia Brasileira de Neurologia (ABNEURO) (2023), Academia Brasileira de Neurologia (ABNEURO) (2021), Vascular.pro (2023) e Biblioteca Virtual em Saúde - Ministério da Saúde (2015).

## 1.2 Tecnologias assistivas e monitoramento

Segundo dados da Organização Mundial de Saúde (2011), os investimentos em intervenções aplicadas à saúde de <sup>1</sup>*best buy*, são pagos ao decorrer do tempo, sendo capazes de gerar lucro aos países investidores. Uma vez que os indivíduos em tratamento tendem a se recuperar, permitindo com que eles recuperem a capacidade motora, mesmo que parcialmente, deste modo, permitindo a retomada de uma vida próspera, interagindo ativamente de atividades diárias e retornando ao trabalho. Ou seja, em 10% de redução na taxa de mortalidade por AVC reduziria as perdas econômicas nos países de baixa e

<sup>1</sup> Investimento em reabilitação de indivíduos com algum tipo de distúrbio neurológico

média renda em cerca de US\$ 377 bilhões de dólares no período de 14 anos, isto é, de 2011 a 2025. Tendo-se uma média de US\$ 25 bilhões de dólares por ano, conforme ilustra a Figura 2. Essa soma de 377 bilhões de dólares é de pouco mais do que o triplo do custo anual da ampliação das intervenções de *best buy* para doenças cardiovasculares, que é de 120 bilhões de dólares.

Figura 2 – Previsão de retorno financeiro após investimento.

Cardiovascular disease (ischaemic heart disease and stroke)	Cumulative figure for 2011-2025 (US\$ billions)	Average annual figure for 2011-2025 (US\$ billions)
Cost of "best buy" interventions (scaled-up response)	120	8
Projected economic benefit (10% reduction in CVD mortality)	377	25

Fonte: Organização Mundial de Saúde (2011).

A partir disso, torna-se palpável a necessidade de desenvolvimento de novas tecnologias voltadas à reabilitação de movimentos em indivíduos com distúrbios neurológico, tal qual o AVC, cujas sequelas podem afetar diversas funcionalidades cognitivas e motoras do enfermo, tais como: redução da sensibilidade ao toque, dificuldade durante a fala, perda de memória, lentidão de raciocínio e limitação de mobilidade (CHEN et al., 2019; CHA et al., 2022).

Em casos de restrições da mobilidade, monitorar as atividades dos pacientes pode ser de grande importância para avaliar a efetividade do tratamento e ajustar as intervenções terapêuticas de acordo com as necessidades individuais de cada paciente. Desta maneira, pode-se elevar a chance de reinserção do paciente nas atividades sociais, melhorando sua qualidade de vida e promovendo independência (LANGHORNE; COUPAR; POLLOCK, 2009). Em concordância com Leong et al. (2022), o qual define que o comprometimento da mobilidade pode estar relacionado também a fatores sociais, como o aumento da dependência funcional, a diminuição da qualidade de vida e a participação social do indivíduo.

Contudo, para mitigar este problema, estudos envolvendo a elaboração de novos dispositivos de Tecnologia Assistiva (TA) vem sendo realizados, tais como o trabalho Gavrila e Davis (1996), onde os autores apresentaram um método de reconhecimento de gestos humanos monitorados por vídeos, cujo trabalho demonstrou eficácia para reconhecer em tempo real as atividades performadas.

Posteriormente, o estudo Au, Dilworth e Herr (2006) propôs um emulador ajustável pertinente à biomecânica da caminhada humana, de modo a melhorar a performance em indivíduos amputados. De forma similar em termos de aplicação, o trabalho Syed, Kausar e Sattar (2021), utilizou Sensores Eletroencefálicos (SEEGs) juntamente com uma interface cérebro-máquina, cujos procedimentos foram capazes de elaborar os comandos

a serem realizados em tempo real pelo dispositivo acoplado ao membro amputado do paciente.

Em vez disso, podem ser utilizados métodos de *Machine Learning* (Aprendizado de Máquina) (ML) para reconhecer a atividade humana, tal como realizado por Turaga et al. (2008), ou identificar as atividades e também fornecer evidências sobre a reabilitação de pacientes Pós-AVC, como proposto por Zhou e Hu (2008).

Para realizar o reconhecimento computacional dos movimentos, diversos trabalhos utilizaram métodos computacionais para tratamento dos dados, bem como técnicas de ML e Redes Neurais Artificiais (RNAs) para identificar as atividades propostas. Por exemplo, em Preece et al. (2009b) foi apresentado um método comparativo para extrair atributos dos sinais fornecidos por um acelerômetro e um classificador *k-Nearest Neighbours* (k Vizinhos mais próximos) (k-NN) para identificar os movimentos.

Já em Ofii et al. (2014), foi apresentado uma nova representação das ações humanas utilizando um *dataset* oriundo de um sistema de captura de movimento em vídeo para análise em tempo real, onde era verificado a sequência de atividades do esqueleto humano como um todo.

Em suma, o uso de tecnologia para localização *indoor*, como <sup>2</sup>*beacons* e sistemas de triangulação de sinais, possibilita identificar a posição de um indivíduo dentro de um espaço fechado, como uma residência ou uma clínica médica, por exemplo Morita et al. (2018). Tais conjuntos são compostos por um sistemas de comunicação sem fio, como *Bluetooth*, *Wi-Fi* ou *Ultra-Wideband* (Banda Ultra Larga) (UWB), sendo em muitos casos utilizados com acelerômetros e giroscópios, os quais são capazes de medir o movimento do corpo em tempo real, fornecendo informações sobre a postura, a velocidade e a aceleração dos movimentos do ser humano (NOGUEIRA et al., 2014).

Uma vez que, o comprometimento do movimento de membros superiores após acidentes, traumas ou lesões neurológicas pode resultar em alterações a longo prazo na capacidade funcional e no desempenho de atividades (DOMAN et al., 2016), que em virtude da limitação do movimento, reduz a frequência de utilização do membro afetado.

Por outro lado, também é possível classificar os movimentos através de um ambiente monitorado conforme resultados apresentados em Tharwat et al. (2018), onde os autores posicionaram as *Inertial Measurement Units* (Unidades de Medição Inercial (IMUs) na região do tórax, pernas e braços dos voluntários para aquisição dos sinais, e identificar as atividades executadas por meio de métodos de ML.

Assim, o monitoramento de Atividades de Membros Superiores (AMS) podem auxiliar as intervenções e contribuir para a recuperação da capacidade funcional do membro <sup>3</sup>parético e no aumento da atividade (POHL et al., 2022). Por exemplo, o estudo de Da-Silva et al. (2018), cujos resultados mostraram que a resposta dada pelo acelerômetro

---

<sup>2</sup> Dispositivos eletrônicos, transmissores de localização através de comunicação sem fio

<sup>3</sup> Que tem paresia, restrição motora

aumentou a atividade do braço prejudicada em pacientes pós-AVC.

Os resultados do estudo proposto por Bernal et al. (2021), indicam que os algoritmos de ML sendo feito de modo supervisionado, são capazes de classificar e rastrear atividades de reabilitação em indivíduos pós-AVC.

Deste modo, os autores Sheng et al. (2022), empregaram Sensores Eletromiográficos (SEMGs) para obtenção de sinais elétricos através da contração e extensão muscular, de modo que a sinergia proveniente desta conversão seja utilizada para quantificar as funções motoras de membros superiores em pacientes pós-AVC, ou para uma classificação em tempo real dos movimentos de membros superiores a partir de técnicas de ML (ANTUVAN et al., 2016).

Por outro lado, os autores Burns, Adeli e Buford (2020) por meio de SEMGs e RNAs, processaram os dados da coleta feita por pacientes pós-AVC em reabilitação e realizaram o reconhecimento destas atividades de membros superiores.

Pesquisas recentes demonstraram a vasta aplicabilidade destas classificações utilizando sensores inerciais, capaz de estimar atitudes e ângulos das articulações de Membros Inferiores (MIs) (FRANCELINE et al., 2022), e superiores (ZABAT et al., 2019). Passando pelo reconhecimento da intenção do movimento de membros superiores (CUI et al., 2022), até para o desenvolvimento de uma plataforma de monitoramento de atividade para reabilitação em pacientes pós-AVC, realizado pelos autores Oliveira et al. (2022).

Embora haja um aumento do uso da TA nas últimas décadas, a qual, contribui para ampliar a inserção e participação social destes indivíduos, existe um déficit entre a necessidade e disponibilidade de TA, dado por uma série de fatores sociais, demográficos e estruturais (MACLACHLAN et al., 2018), contribuindo também com a carência quantitativa acerca dos dispositivos de TA, ou seja, a oferta de dispositivos desenvolvidos é menor do que a quantidade necessária (MONT et al., 2021).

Por conseguinte, neste estudo é proposto e desenvolvido um armazenamento em nuvem para a coleta de dados, de modo a identificar 7 tipos de atividades diárias realizadas com membros superiores, sendo utilizados sensores inerciais para a aquisição dos dados, métodos de processamento de dados para tratamento dos sinais crus, e técnicas de ML e redes neurais para classificar as atividades de modo supervisionado. Com isso, espera-se que os resultados provenientes das classificações atinjam o limiar mínimo de 85% de acurácia na predição das classes, visando fornecer bases sólidas para trabalhos futuros similares.

### 1.3 Objetivos

O objetivo geral deste estudo é realizar a identificação de atividades cotidianas realizadas com membros superiores em indivíduos saudáveis e pós-AVC, sendo empregado sensores inerciais posicionados em membros superiores (pulsos esquerdo e direito).

Assim, foram definidos os seguintes objetivos específicos:

- Revisão bibliográfica sobre os principais métodos computacionais utilizados para extração de características, identificação e classificação atividades cotidianas;
- Coleta de dados empregando IMUs em ambiente simulado, realizando atividades preestabelecidas, e armazenando *backup* em nuvem;
- Implementar o algoritmo de pré-processamento dos sinais para leitura de dados, segmentação e extração de características para classificação dos movimentos;
- Implementar e validar os algoritmos baseados em ML para classificação/identificação das atividades diárias;
- Escolha/seleção de características mais significativas em algoritmos de aprendizado de máquinas.

## 1.4 Organização do texto

Nesse primeiro capítulo foi realizada a contextualização, motivação, proposta e apresentação dos objetivos deste projeto.

Abaixo serão descritos brevemente os conteúdos dos capítulos desta dissertação:

- **Capítulo 2** - Apresenta as bases teóricas necessárias de processamento digital de sinais para reconhecimento das atividades de membros superiores utilizando IMUs, bem como os métodos de coleta de dados, extração das características e classificação das atividades realizadas através de RNAs. Sendo assim, serão abordados temas como: sensores inerciais, sintetização dos dados, banco de filtros digitais, além de operadores para análise do sinal, tais como valor eficaz *Root Mean Square* (Raíz Quadrada da Média) (RMS), assimetria e achatamento da curva.
- **Capítulo 3** - Apresenta o desenvolvimento dos métodos propostos mantendo a ordem de execução, serão demonstrados o modo de realização das etapas de coleta de dados, tratamento dos sinais e por fim a classificação das atividades utilizando ML e RNAs;
- **Capítulo 4** - São apresentados em detalhes os resultados obtidos durante a fase de testes com as discussões atribuídas durante cada etapa;
- **Capítulo 5** - É apresentada a conclusão acerca dos resultados obtidos e trabalhos futuros.





---

## Capítulo 2

# Materiais e Métodos

---

Neste capítulo são descritas as principais metodologias utilizadas neste trabalho. O intuito do mesmo é familiarizar o leitor com as técnicas que serão utilizadas. Iniciando-se pela aquisição de dados, a qual utilizou-se duas IMUs para fornecimento dos sinais inerciais durante a aquisição dos dados, em que foram realizadas 7 atividades distintas. As coletas foram realizadas dentro de um ambiente mobiliado, controlado e monitorado por uma câmera de vídeo, pela qual viabilizou a criação dos dados de referência para realizar o reconhecimento supervisionado proposto. Além disso, as demais atividades foram estabelecidas como atividades 0 (zero), ou seja, atividades que não serão classificadas neste trabalho. Desta maneira, ações executadas durante os movimentos de trocas posturais, deslocamentos, movimentos involuntário dos membros superiores como coçar-se ou gesto de olhar no relógio de pulso, e tirar cabelo da frente dos olhos foram desconsideradas. A partir destas configurações, os sinais foram capturados pelos sensores e enviados para armazenamento em nuvem em forma de *backup*. Em seguida, o algoritmo computacional elaborou o *download* dos arquivos e deu início ao pré-processamento dos dados para os métodos e técnicas computacionais utilizados na análise de reconhecimento de padrões dos movimentos executados durante as 7 coletas.

### 2.1 Atividades de membros superiores

Com o objetivo de se definir as principais atividades a serem monitoradas, utilizaremos o protocolo <sup>1</sup>*Motor Activity Log* (Registro de Atividade Motora) (MAL), proposto por Taub et al. (2011), para definir quais atividades são de fato ideais para os indivíduos

---

<sup>1</sup> Escala utilizada pela fisioterapia com o intuito de avaliar a habilidade funcional motora da utilização espontânea do membro superior afetado em atividades do dia a dia.

em reabilitação. Assim, possibilitando realizar atividades que são comumente utilizadas durante os exercícios de reabilitação motor ocasionados por algum tipo de distúrbio neurológico por meio do protocolo MAL, tal como os proposto pelos estudos Lee et al. (2004), Winckel e Gauthier (2019) e Anjos et al. (2021).

A definição inicial das atividades de membros superiores a serem classificadas foi obtida através de 45 atividades citadas no estudo de referência Annabel McDermott (2023), que foram detalhadas na Tabela 1. Com base nessas informações, foi elaborado um protocolo adaptado contendo as 7 atividades selecionadas, as quais são descritas na Tabela 2.

Tabela 1 – Protocolo de atividades MAL-45.

1-	Ligar/ desligar luz	16-	Retirar os sapatos	31-	Retirar notas de dinheiro da carteira
2-	Abrir/ fechar gaveta	17-	Levantar da cadeira	32-	Pegar moedas
3-	Retirar item da gaveta	18-	Afastar a cadeira antes de sentar	33-	Tirar as chaves do bolso
4-	Atender o telefone	19-	Puxar a cadeira após sentar	34-	Puxar um zíper
5-	Limpar um balcão	20-	Pegar copo e tomar água	35-	Despejar líquido da garrafa no copo
6-	Sair de um carro	21-	Escovar os dentes	36-	Fechar o cinto da calça
7-	Carregar objetos com as mãos	22-	Passar maquiagem/ cremes no rosto	37-	Abrir uma lata (de bebida)
8-	Girar maçaneta e abrir porta	23-	Destrancar porta (com chave)	38-	Tirar a tampa de um frasco de remédio
9-	Usar controle de TV	24-	Escrever em papel	39-	Usar teclado numérico
10-	Lavar as mãos	25-	Abrir geladeira	40-	Digitar
11-	Abrir e fechar a torneira	26-	Usar garfo ou colher para comer	41-	Pôr/ retirar o relógio do pulso
12-	Secar as mãos	27-	Pentear o cabelo	42-	Pôr/ retirar os óculos
13-	Vestir as meias	28-	Pegar xícara pela alça	43-	Bombear um dispenser de sabão
14-	Retirar as meias	29-	Abotoar a camisa	44-	Usar o cartão no caixa eletrônico
15-	Calçar sapatos	30-	Comer sanduíche com as mãos	45-	Usar o controle do ar condicionado

Fonte: Adaptada de Annabel McDermott (2023).

Após a elaboração deste protocolo, avaliou-se quais destas 45 atividades seriam mais condizentes ao ambiente em que os movimentos seriam coletados e sua respectiva aplicabilidade. Assim, definiu-se 7 atividades principais, que são formadas pela junção de algumas das atividades mostradas na Tabela 1, e as atividades em que não houveram interesse em realizar o reconhecimento. Desta forma, foram nomeadas em forma de 8 variáveis distintas, tal como visualizadas na Tabela 2.

Tabela 2 – Definição das atividades de membros superiores

<b>Número e nome das atividades</b>	<b>Descrição das atividades</b>	<b>Números provenientes da escala MAL-45</b>
<b>0 - Movimentos aleatórios</b>	Trocas posturais, deslocamentos, coçar braços e cabeça, derrubar/ pegar copo.	N/A
<b>1- Porta</b>	Abrir/ fechar porta, retirar item	8
<b>2- Gaveta</b>	Abrir/ fechar gaveta, retirar item	2, 3
<b>3- Alimentar</b>	Comer com as mãos, segurar copo e tomar água	20, 26, 28, 30
<b>4- Estudo</b>	Escrever no papel, segurar livro e caneta	24
<b>5- Telefone</b>	Segurar telefone, digitar no teclado, Falar ao telefone	4, 39 e 40
<b>6- Cadeira</b>	Afastar cadeira ao sentar, puxar cadeira ao sentar	17, 18 e 19
<b>7- Varrer</b>	Carregar vassoura e pá; limpar a mesa e a sala	5 e 7

Fonte: Autor.

## 2.2 Ambiente controlado

O ambiente controlado foi fundamental para a definição das tarefas mais adequadas em relação ao espaço disponibilizado e condizentes com as atividades propostas na Figura 1.

Visto que o espaço utilizado, conforme mostrado na Figura 3, se assemelhava a uma sala de jantar completa, com todos os móveis e utensílios necessários para a execução das atividades cotidianas preestabelecidas na Seção 2.1, proporcionou um ambiente realista para a realização dos experimentos e a coleta de dados relacionados ao reconhecimento dessas atividades juntamente com o apoio de uma câmera de vídeo para monitoramento do local e fornecimento de imagens para validar as atividades realizadas, cujo procedimento é classificado como padrão ouro e tem sido utilizada em diversos estudos, como no caso do estudo de Hensley et al. (2022), onde especialistas conduziram uma análise minuciosa para avaliar a confiabilidade e a validação em vídeo das atividades de corrida em 2 dimensões.

Este processo de validação por imagem do ambiente foi realizado com o apoio de uma câmera de vídeo posicionada estrategicamente, conforme apresentado na Figura 4, de modo que captasse as áreas mais importantes do ambiente de coleta, permitindo que todas as atividades realizadas fossem gravadas. Para isso, utilizou-se uma câmera com grande angular capaz de capturar imagens com até 170°, possibilitando a visualização completa do cômodo monitorado, para mais detalhes da câmera vide Apêndice A.

Figura 3 – Ambiente da coleta



Figura 4 – Posicionamento da camera



Fonte: Autor.

## 2.3 Sensores inerciais e identificação de atividades

Os sensores inerciais são normalmente constituídos de giroscópios e acelerômetros que fornecem respectivamente velocidade angular e aceleração linear. Os dispositivos de detecção utilizados possuem acelerômetros e giroscópios triaxiais, e também possuem um microcontrolador embarcado com um *firmware* capaz de fornecer ângulos de rotação nos três eixos axiais. Neste trabalho, tais sensores serão empregados para monitorar a movimentação dos membros superiores do corpo humano. Maiores informações sobre o sensor foram disponibilizados no Apêndice B.

Sensores inerciais vestíveis são dispositivos que podem ser fixados em várias partes do corpo humano, dependendo do tipo de movimento que se pretende monitorar. Por exemplo, sensores fixados nos pulsos podem ser usados para monitorar a atividade física geral, enquanto sensores fixados nos tornozelos podem ser usados para monitorar a marcha e o equilíbrio. Sensores fixados na coluna vertebral podem ser usados para monitorar a postura e a marcha, e sensores fixados na cabeça podem ser usados para monitorar o movimento dos olhos e da cabeça (YANG et al., 2022).

O reconhecimento da atividade humana é abordado em diversos trabalhos com diferentes procedimentos e técnicas empregadas, como o trabalho dos autores Burns, Adeli e Buford (2020) que utilizam sinergia muscular e SEMGs para aquisição dos dados.

Por outro lado, também é possível realizar esta identificação de movimentos através de um ambiente monitorado conforme resultados apresentados em Tharwat et al. (2018), sendo utilizado a extração de atributos em função do tempo e de frequência para análise dos dados.

Após a extração de características, técnicas de aprendizado de máquina, tais como Regressão Logística, k-NN e *Support Vector Machine* (Máquina de Vetores de Suporte) (SVM), são comumente utilizadas para treinamento e identificação, conforme utilizadas nos trabalhos Preece et al. (2009a) e Burns, Adeli e Buford (2020).

Diferente de Burns, Adeli e Buford (2020), Cui et al. (2022) e Lin et al. (2018), é pro-

posto neste trabalho identificar as atividades diárias realizadas com membros superiores utilizando sensores inerciais e técnicas de Aprendizado de Máquina e Redes neurais.

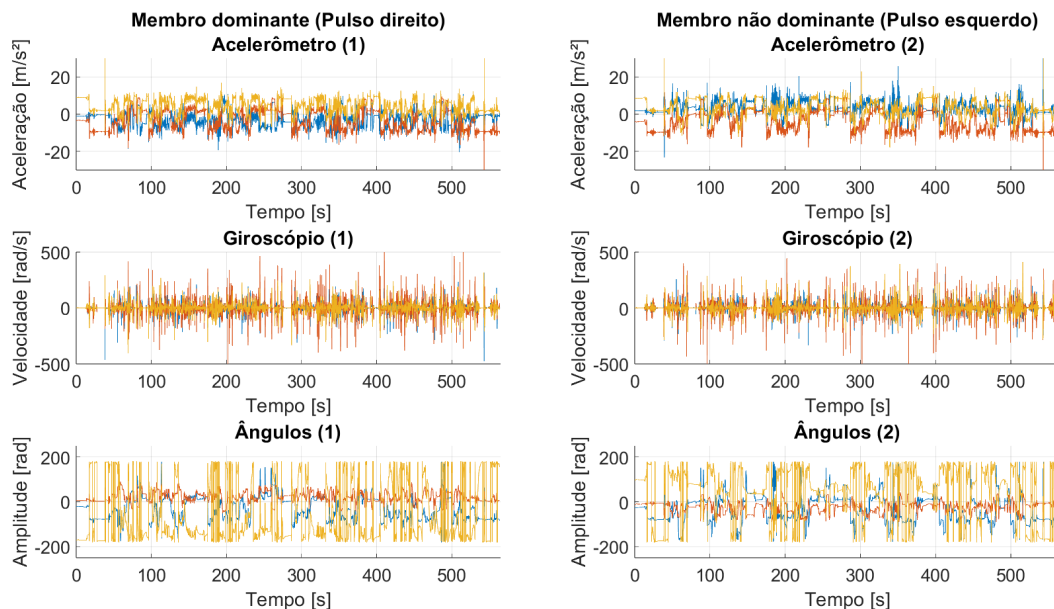
## 2.4 Pré-Processamento

Nesta seção serão introduzidos os processos metodológicos utilizados para reconhecimento das atividades de membro superiores em indivíduos saudáveis.

O pré-processamento de dados é uma etapa fundamental ao lidar com a classificação de atividades dos membros superiores usando sensores inerciais. Ele envolve uma série de técnicas e procedimentos que visam melhorar a qualidade dos dados coletados, reduzir a dimensionalidade dos dados, mitigar ruídos e extrair características relevantes para a classificação correta das atividades.

Neste trabalho, utilizou-se duas IMUs para obtenção dos dados inerciais. Sendo um sensor posicionado no punho direito e o outro sensor no punho esquerdo. Estes sinais são demonstrados na Figura 5, em que “(1)” representa os sinais captados pelos movimentos executados pelo membro dominante (braço direito) e “(2)” ilustram os sinais fornecidos pelo sensor posicionado no membro não dominante (braço esquerdo).

Figura 5 – Dados inerciais fornecidos pelas IMUs



Fonte: Autor

Em seguida, os dados foram segmentados em janelas (intervalos de tempo) menores, permitindo que essas fases sejam analisadas separadamente, facilitando a extração de características relevantes para cada fase específica.

Para garantir somente os dados relevantes para a classificação, foi realizada a filtragem e normalização dos dados para mitigar ruídos e interferências inerentes ao ambiente e

aos próprios sensores, pelos quais podem ser capturados durante a aquisição dos dados, ademais ajustar as faixas de medição ou unidades de medida que os diferentes tipos de sensores podem conter, possibilitando a extração adequada das características.

### 2.4.1 Extração de atributos

A extração de características é uma etapa essencial no pré-processamento de dados de sensores inerciais para a classificação de atividades dos membros superiores, cuja finalidade é simplificar a representação dos dados (inerciais) capturados, reduzir sua dimensionalidade e enfatizar os aspectos mais relevantes para a classificação (PREECE et al., 2009b).

Desta forma, contribui para o reconhecimento de padrões (BURNS; ADELI; BUFORD, 2020) e classificação de atividades realizadas com membros superiores (LIU et al., 2021). Ao extrair características relevantes de um sinal, é possível representar o sinal de uma maneira mais compacta e significativa, fornecendo informações importantes com menor dimensionalidade.

Existem diferentes tipos de atributos que podem ser extraídas de sinais inerciais, podendo ser dados temporais, espectrais e estatísticos. As características temporais estão relacionadas às propriedades do sinal no domínio do tempo, como média, variância, covariância, amplitude e tempo de execução dos movimentos para análise dinâmica do sinal (LIU et al., 2022).

Os atributos espectrais, por outro lado, estão relacionados às propriedades do sinal no domínio da frequência, tais como a *Fast Fourier Transform* (Transformada Rápida de Fourier) (FFT) e *wavelet*, para análise distributiva diferentes frequências, frequência dominante e seus coeficientes, demonstrando informações sobre a composição espectral do sinal (FILIPPESCHI et al., 2017).

Em contra partida, os dados estatísticos comumente utilizados são média, desvio padrão, valores máximos e mínimos, correlação entre eixos, achatamento/alongamento e assimetria da curva característica do conjunto de dados representado por *kurtosis* e *skewness* (LIU et al., 2022).

Diversos estudos acerca de monitoramento de atividades já foram desenvolvidos, estabelecendo métodos para embasamento sobre o reconhecimento de membros superiores através de sensoriamento e processamento de dados em algoritmos computacionais. Dentre estes, destacam-se os trabalhos que envolvem análise de atributos para extração, técnicas de aprendizado de máquina para classificação das atividades, tais como, k-NN, *Logistic Regression* (Regressão Logística) (LR), *General Regression Neural Network* (Rede Neural de Regressão Genérica) (GRNN), *Radial Basis Function* (Função de Base Radial) (RBF), *Decision Trees* (Árvores de Decisão) (DT), *Backpropagation Neural Net* (Rede Neural com Retropropagação) (BPNN), SVM e *Stochastic Configuration Network* (Rede de Configuração Estocástica) (SCN), conforme apresentado na Tabela 3.

Tabela 3 – Abordagens metodológicas utilizadas em estudos correlatos.

Trabalhos	Sensores	Características	Técnicas
(PREECE et al., 2009b)	Acelerômetros	FFT média correlação	k-NN
(LIU et al., 2021)	IMUs	Desvio padrão picos (max-min) range interquartilico	k-NN LR GRNN RBF
(LIU et al., 2022)	Piezoelétricos	média RMS energia variância skewness kurtosis desvio padrão	DT BPNN SVM SCN
(BURNS; ADELI; BUFORD, 2020)	Eletromiográficos	desvio padrão média potencia <i>wavelet</i>	k-NN SVM

Fonte: Autor.

Em suma, este procedimento ajuda a melhorar a eficiência computacional, permitindo o uso de algoritmos mais rápidos e eficazes na etapa de classificação. Além disso, características bem escolhidas e representativas podem aumentar a capacidade de discriminação entre as diferentes atividades dos membros superiores, melhorando a precisão da classificação final (PREECE et al., 2009a).

### 2.4.2 Aumento do número de dados


A sintetização de dados é uma técnica utilizada no pré-processamento de dados para criar variações adicionais nos dados de treinamento, a fim de melhorar o desempenho e a generalização do modelo de aprendizado de máquina. Existem diversas abordagens de aumento de dados que são utilizadas neste contexto, dentre elas se destacam: a rotação randomizada dos eixos triaxiais, o deslocamento aleatório, o redimensionamento, a reflexão e a distorção. Essas técnicas permitem criar um conjunto de dados maior e mais diversificado, ajudando o modelo a aprender padrões mais gerais e a evitar o *overfitting* aos dados de treinamento originais.

Ao aplicar rotações aleatórias aos dados inerciais, é possível criar novas instâncias de dados que mantêm as características principais, mas têm variações nas orientações. Isso pode ser útil para treinar modelos de aprendizado de máquina que precisam ser robustos a diferentes orientações dos dados.

Esta técnica envolve aplicar transformações aleatórias de rotação aos dados inerciais.

Essas transformações podem incluir rotações em torno dos eixos  $x$ ,  $y$  e  $z$  em ângulos aleatórios, cujos movimentos são denominados de *roll*, *pitch* e *yaw*, conforme ilustrado na Figura 6 e calculados através das matrizes de rotação de cada eixo, tal como mostra as Equações 1, 2 e 3. A finalidade é simular variações que podem ocorrer nos dados, como diferentes orientações do dispositivo de captura ou variações na posição do objeto em movimento.

Figura 6 – Ângulos de Roll, Pitch e Yaw.



Fonte: Autor.

- Matriz de rotação do eixo  $x$ .

$$M_X(\phi) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\phi) & -\text{sen}(\phi) \\ 0 & \text{sen}(\phi) & \cos(\phi) \end{bmatrix} \quad (1)$$

- Matriz de rotação do eixo  $y$ .

$$M_Y(\theta) = \begin{bmatrix} \cos(\theta) & 0 & \text{sen}(\theta) \\ 0 & 1 & 0 \\ -\text{sen}(\theta) & 0 & \cos(\theta) \end{bmatrix} \quad (2)$$

- Matriz de rotação do eixo  $z$ .

$$M_Z(\psi) = \begin{bmatrix} \cos(\psi) & -\text{sen}(\psi) & 0 \\ \text{sen}(\psi) & \cos(\psi) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3)$$



Após a coleta de dados realizada em consonância com as atividades apresentadas na Seção 2.1, verificou-se uma assimetria na quantidade de amostras por tipo de atividade monitorada, sendo esta, apresentada na Tabela 4 e, após a sintetização dos dados, observou-se mais homogeneidade da quantidade de amostras, conforme mostrado pela Tabela 5.

Tabela 4 – Assimetria quantitativa amostral dos dados originais

<b>Atividade</b>	0	1	2	3	4	5	6	7
<b>Amostras</b>	759	108	52	238	262	233	310	210
<b>(%)</b>	34.94	4.97	2.39	10.96	12.06	10.73	14.27	9.67

Fonte: Autor.

Tabela 5 – Assimetria quantitativa amostral após aumento dos dados

<b>Atividade</b>	0	1	2	3	4	5	6	7
<b>Amostras</b>	759	936	912	904	801	960	900	820
<b>(%)</b>	10.86	13.39	13.04	12.93	11.46	13.73	12.87	11.73

Fonte: Autor.

Para estabilizar a quantidade de amostras, foram comparadas algumas técnicas para compensar a assimetria na quantidade de amostras/classes, como o *Data-level Method* que pode tanto gerar dados para classes minoritárias *oversampling* quanto remover amostras das classes majoritárias *undersampling*, com o objetivo de equacionar a quantidade de amostras para todas as classes de dados. Com a abordagem *Cost-Sensitive*, são aplicadas penalidades ao algoritmo de aprendizagem de modo a impor um alto custo às classes menos representadas e um baixo custo àquelas com maior quantidade numérica. Em Xie et al. (2019), foi desenvolvido um método chamada *Generative Learning*, que considerou a geração de novos dados com base na análise da distribuição dos dados originais a partir da análise na vizinhança de dados adotando para este caso o *Gaussian Mixed Model* (Modelo Misto Gaussiano) (GMM) para análise tanto das classes majoritárias quanto minoritárias para gerar novos dados sintéticos.

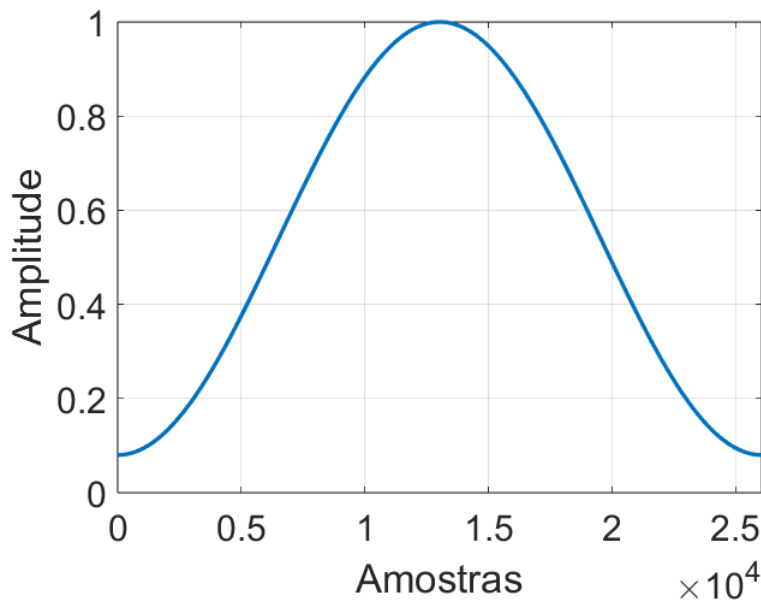
### 2.4.3 Janelamento de Hamming

Trata-se de uma técnica utilizada em análises de espectro de sinais digitais para reduzir o vazamento espectral, que ocorre ao realizar a análise espectral com uma janela retangular, pois corta abruptamente os sinais na transição de uma janela para a próxima. Isso resulta em frequências <sup>2</sup>espúrias ou "vazamentos" aparecendo no espectro, que podem dificultar a interpretação correta das frequências presentes no sinal.

<sup>2</sup> Incertas, hipotéticas, falsas.

A janela de Hamming é uma função de janela que atenua gradualmente as bordas do sinal, no qual retorna os dados em função do número de pontos de cada sinal simetricamente, reduzindo o vazamento espectral. Ela possui uma forma de cosseno suave, tal como representada pela Figura 7 e é definida matematicamente pela Equação 4.

Figura 7 – Hamming genérico



Fonte: Autor.

$$\omega(n) = 0.54 - 0.46\cos\left(\frac{2n}{N-1}\right), 0 \leq n \leq N, \quad (4)$$

onde  $\omega(n)$  é o valor da janela de Hamming para o ponto  $n$ , e  $N$  é o tamanho total da janela.

Isso resulta em espectros mais limpos e mais concentrados nas frequências reais do sinal, facilitando a identificação e interpretação das componentes de frequência presentes, além de preservar a informação temporal do sinal. Graficamente, um recorte de 10s do sinal cru é ilustrado pela Figura 8 e a aplicação de Hamming ponto a ponto neste *frame* é visualizada pela Figura 9.

Neste estudo, o janelamento de Hamming foi utilizado para atenuar as bordas do sinal, reduzir o vazamento espectral e mitigar o <sup>3</sup> *aliasing*, bem como melhorar a precisão e a interpretabilidade da análise espectral.

## 2.5 Algoritmos de classificação

Algoritmos que buscam aprender modelos que possam categorizar dados de entrada em diferentes classes ou categorias. Esses modelos são construídos com base em padrões

<sup>3</sup> Distorções causadas pela sobreposição espectral do sinal.

Figura 8 – Sinal do giroscópio do membro dominante recortado em 10s





Figura 9 – Janelamento de Hamming aplicado ponto a ponto no recorte



Fonte: Autor.

e características identificáveis nos dados de treinamento, de modo que possam fazer previsões ou atribuir rótulos corretos a novos dados não observados.

Os classificadores podem ser usados para tarefas de classificação binária, onde os dados são divididos em duas classes distintas, ou classificação multiclasse, onde há mais de duas classes, tal como a proposta deste estudo. Além disso, há uma ampla gama de aplicações em diversos domínios científicos, sendo utilizados para reconhecer atividades de movimento humano com acelerômetros (PREECE et al., 2009b), identificar atividades performadas com membros superiores em ambiente monitorado (THARWAT et al., 2018), realizar previsões das atividades diárias de membros superiores realizadas por pacientes Pós-AVC (LIN et al., 2018) e classificar atividades de membros superiores com sensores eletromiográficos (BURNS; ADELI; BUFORD, 2020).

Resumidamente, os classificadores supervisionados recebem um conjunto de dados de treinamento contendo exemplos rotulados, nos quais o algoritmo aprende a mapear as características de entrada às classes correspondentes. Destes, k-NN e SVM são exemplos comuns de classificadores supervisionados, ademais RNAs também podem ser utilizadas para classificação de AMS, tal como mostra a Tabela 6.

### 2.5.1 k-Nearest Neighbors

É definido como um algoritmo de classificação e regressão de aprendizado de máquina é um método de aprendizado não paramétrico, ou seja, não faz suposições explícitas sobre a distribuição dos dados. Quando uma nova instância de dados precisa ser classificada, o algoritmo calcula a distância entre essa instância, normalmente a distância euclidiana (THARWAT et al., 2018) dado pela Equação 5, e todos os exemplos de treinamento fornecidos por um conjunto de treinamento  $X = \{(x_1, y_1), \dots, (x_N, y_N)\}$ .

Tal que,  $x_i \in X$  representa a amostra de treinamento,  $y_i \in \{\omega_1, \omega_2, \dots, \omega_c\}$  descreve a classe da amostra de treinamento, independente ao número  $i$  da amostra, com  $N$  cor-

Tabela 6 – Técnicas de aprendizado de máquina utilizadas em trabalhos similares.

Trabalho	Atividade realizada	Técnica e precisão média
(PREECE et al., 2009b).	Reconhecimento de atividades dinâmicas com acelerômetros.	k-NN - (87.3%).
(THARWAT et al., 2018).	Reconhecimento de AMS em ambiente monitorado.	k-NN - (90.0%). SVM - (92.1%).
(LIN et al., 2018).	Predição de AMS em pacientes Pós-AVC.	SVM - (98.6%)
(BURNS; ADELI; BUFORD, 2020).	Classificação de AMS com SEMGs.	k-NN - (63.0%) SVM - (61.0%)
(SYED; KAUSAR; SATTAR, 2021).	Detecção de AMS com SEMGs.	RNAs - (88.65%)

Fonte: Autor.

responde ao número total de amostras no treinamento e  $c$  representa o número total de classes, de modo a escolher o valor de amostra de treinamento  $k$  ( $i = 1, 2, \dots, N$ ).

$$d(x_i, x_j) = \sum_{k=1}^d (x_{ik} - x_{jk})^2, \quad (5)$$

sendo:

- $d(x_i, x_j)$  representa a distância entre as amostras  $x_i$  e  $x_j$ ,
- $x_i$  e  $x_j \in R^m$ ,  $x_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}$ ,
- $m$  é a dimensão, ou seja, número de atributos e de amostras.

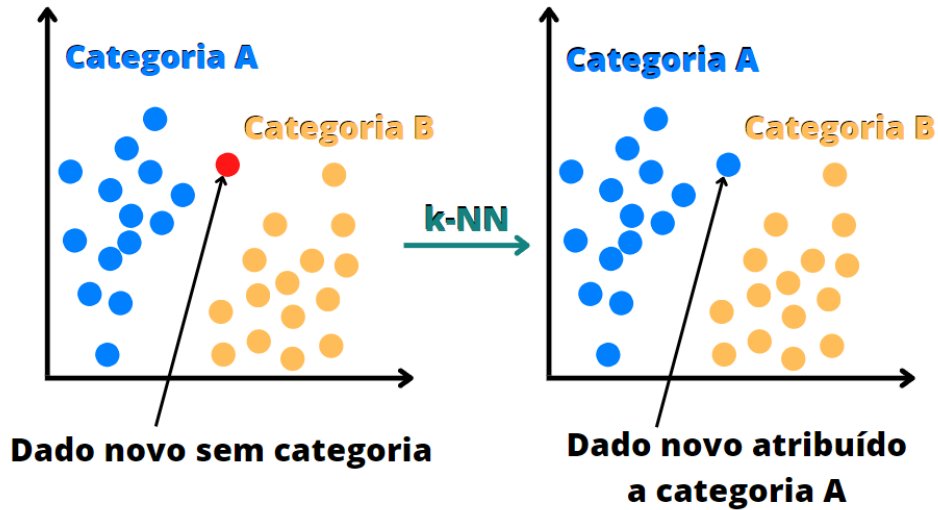
Em seguida, seleciona os “ $k$ ” exemplos de treinamento mais próximos. A classe mais frequente entre esses “ $k$ ” vizinhos é atribuída à nova instância como sua classe prevista, como ilustra a Figura 10.

O K-NN também pode ser usado para tarefas de regressão, onde em vez de atribuir classes, o algoritmo calcula a média ou a mediana dos valores de saída das “ $k$ ” instâncias mais próximas e atribui esse valor à nova instância como sua saída prevista.

Uma das vantagens do K-NN é sua simplicidade e facilidade de implementação. Ele também pode lidar com dados não lineares e é robusto a ruídos. Além disso, o K-NN não requer um treinamento explícito, pois os exemplos de treinamento são usados diretamente na fase de previsão.

No entanto, o desempenho do K-NN pode ser afetado pela escolha do valor de “ $k$ ”. Um valor muito baixo de “ $k$ ” pode levar a uma classificação ou regressão instável, enquanto um

Figura 10 – Modelo básico de um classificador k-NN.



Fonte: Autor.

valor muito alto pode diluir a influência dos vizinhos mais próximos. Além disso, o K-NN pode ser computacionalmente intensivo, especialmente em conjuntos de dados grandes.

É importante destacar que o K-NN é sensível à escala dos dados, portanto, normalizar ou padronizar os atributos pode ser necessário para obter melhores resultados. Além disso, a seleção adequada de características e o tratamento de valores ausentes também podem afetar o desempenho do K-NN.

Em resumo, o K-NN é um algoritmo de classificação e regressão que usa a distância entre as instâncias de treinamento e uma nova instância para fazer previsões. Ele é simples de implementar, lida bem com dados não lineares e é robusto a ruídos. No entanto, a escolha adequada do valor de "k" e o pré-processamento dos dados são importantes para obter resultados precisos.

Por outro lado, os classificadores não supervisionados, não possuem rótulos fornecidos nos dados de treinamento, conseqüentemente, o algoritmo busca identificar padrões intrínsecos nos dados e organiza-os em grupos ou *clusters* com base em sua similaridade.

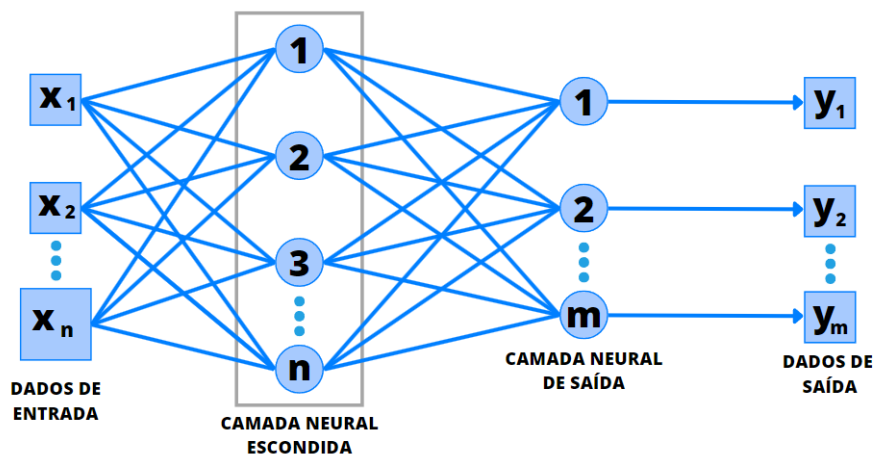
## 2.5.2 Redes Neurais Artificiais

São modelos matemáticos inspirados no funcionamento do sistema nervoso biológico, constituídos de algoritmos de aprendizado de máquina que podem ser utilizadas para resolver uma vasta variedade de tarefas, incluindo análise funcional motora de membros superiores em indivíduos pós-AVC (SZCZEŚNA; BŁASZCZYSZYN; KAWALA-STERNIUK,

2020), detecção de movimentos de membros superiores (SYED; KAUSAR; SATTAR, 2021), reconhecimento de atividades em ambiente sensorado (OTEBOLAKU et al., 2020) e segmentação, detecção e rastreamento de atividades humanas (MARTINDALE et al., 2021; HAQ et al., 2020).

As RNAs são composta por conjuntos de unidades de processamento chamadas neurônios artificiais ou nós, que são organizados em camadas, as quais são definidas basicamente por três tipos principais: a camada de entrada, as camadas ocultas e a camada de saída como ilustrado pela Figura 11. Cada neurônio recebe dados de entrada, realiza uma combinação linear desses dados ponderados por seus pesos sinápticos, passa o resultado por uma função de ativação não linear e envia os dados de saída para os neurônios da camada seguinte.

Figura 11 – Modelo de uma Rede Neural Artificial.



Fonte: Autor.

Durante a fase de treinamento, a rede neural ajusta os pesos sinápticos para otimizar o desempenho do modelo em relação aos dados de treinamento. Isso é geralmente feito usando um algoritmo de otimização, como o Gradiente Descendente, que minimiza uma função de perda que mede a diferença entre as previsões da rede e os rótulos corretos dos dados de treinamento.

O processo de ajuste dos pesos é realizado iterativamente até que a rede alcance um nível satisfatório de desempenho, tendo como característica, a capacidade de aprendizado de recursos, isto é, elas podem aprender automaticamente quais características dos dados são mais relevantes para executar a tarefa em questão, reduzindo assim a necessidade de engenharia de recursos manuais.

Neste estudo, foi realizado um aprendizado supervisionado, captando os atributos por um banco de filtros e operadores estatísticos, e classificando as classes rótuladas

das atividades através de k-NN e reconhecimento de padrões em rede neural, utilizando *toolboxes* do *Matlab*.





---

## Capítulo 3

# Desenvolvimento

---

### 3.1 Representação experimental

Nesta seção é apresentada a plataforma proposta neste estudo para coleta e processamento de dados de sensores inerciais durante a realização de atividades com membros superiores.

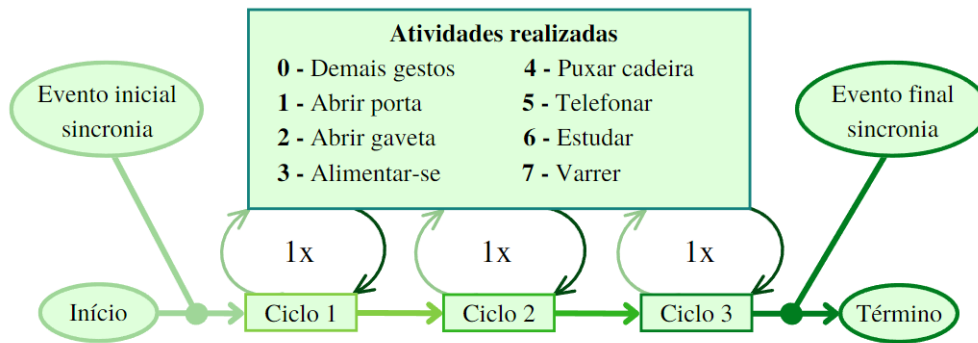
Para a coleta de dados serão empregados protocolos para realização de atividades comuns a pessoas sem restrição motora, as quais foram realizadas com o próprio autor e colaboradores deste trabalho. Cabe ressaltar que todos os participantes deste estudo possuem o membro superior direito como o dominante, sendo as atividades executadas com tempo aproximado de 10 minutos, contendo 3 repetições das atividades escolhidas, em concordância com Oliveira (2023) com intuito do participante exercer movimentos de flexão, extensão, abdução, adução e rotação com os membros superiores (LIU et al., 2021), conforme ilustrado na Figura 12.

Para evitar falhas durante a realização das coletas, um *check-list* orientativo foi elaborado para mitigar possíveis problemas inerentes do processo de aquisição dos dados, tais como: falta de carga nas baterias dos dispositivos, falha de comunicação no pareamento via *bluetooth* dos sensores com o *smartphone* e impor todas as etapas de execução para que os dados sejam adquiridos e enviados a nuvem com sucesso, para mais detalhes, veja o Apêndice C.

### 3.2 Plataforma de aquisição e transmissão de dados

Nesta seção é apresentada a plataforma proposta neste estudo para coleta e pré-processamento de dados de sensores inerciais. Na Figura 13 é apresentado um breve

Figura 12 – Representação das atividades nos 3 ciclos de repetição.




Fonte: Autor.

descritivo do sistema, na qual é possível verificar o uso de dois sensores inerciais posicionados nos pulsos do indivíduo monitorado, sendo o posicionamento apresentado detalhadamente na Figura 14. Os sinais são coletados via protocolo *Bluetooth* e transmitidos via protocolo *File Transfer Protocol* (Protocolo de Transferência de Arquivos) (FTP) para nuvem. O procedimento de coleta e envio para nuvem foi realizado através de um aplicativo desenvolvido em *Android Studio (JAVA)* para esse fim. Já para o processamento e análise dos dados, foi desenvolvido um *script* em Matlab, o qual baixa os dados da nuvem e disponibiliza os mesmos localmente de forma que possam ser utilizados para identificação das atividades monitoradas.

Em seguida, serão apresentados os sensores inerciais utilizados e o aplicativo desenvolvido neste trabalho (BSL Capture).

Figura 13 – Transmissão de dados.



Fonte: Autor.

Os sensores inerciais utilizados são do modelo WitMotion WT901C<sup>1</sup>, disponíveis comercialmente, para obtenção de acelerações lineares e velocidades angulares triaxiais, e

<sup>1</sup> <https://www.wit-motion.com>

Figura 14 – Posicionamento dos sensores.




Fonte: Autor.

ângulos de orientação para os eixos  $x$ ,  $y$  e  $z$ , sendo realizadas coletas com frequência de aquisição de 50Hz. As faixas de medidas nominais de operação do dispositivo são de  $\pm 6g$  para o acelerômetro,  $\pm 2000^\circ/s$  para o giroscópio e  $\pm 180^\circ$  para os ângulos de rotação dos eixos  $x$  e  $z$ , e  $\pm 90^\circ$  para o eixo  $y$ . A resolução nominal é de 0.005g para o acelerômetro e  $0.61^\circ/s$  para o giroscópio. Após calibrado, a acurácia angular é de  $0.05^\circ$  para os eixos  $x$  e  $y$  em condições estáticas e  $0.1^\circ$  com a dinâmica presente para os mesmos eixos. Para maiores informações, consulte o Apêndice B.

O aplicativo "*Biomedical Signals Laboratory (BSL) Capture*" desenvolvido neste trabalho e utilizado para coleta e transmissão de dados, foi projetado na plataforma *Android Studio 2022* com uso do pacote de desenvolvimento disponibilizado pelo fabricante *Wit-Motion* dos sensores inerciais, maiores informações são descritas no Apêndice D. Este aplicativo possibilita a coleta de dados de múltiplos sensores inerciais e a transmissão dos sinais coletados através do FTP em um servidor pré-programado, maiores informações, veja Apêndice D.

Conforme apresentado na Figura 15, o aplicativo possui no centro da tela a visualização dos sensores pareados/configurados. Além disso, mais abaixo na interface gráfica, é possível localizar as configurações de calibração para cada tipo de sensor, a taxa de amostragem e o comando de envio das capturas para o armazenamento via FTP. Neste estudo foi utilizado frequência de aquisição em 50Hz.

Figura 15 – Interface do aplicativo *BSL Capture*.

Fonte: Autor.

### 3.3 Pré-processamento e extração de características

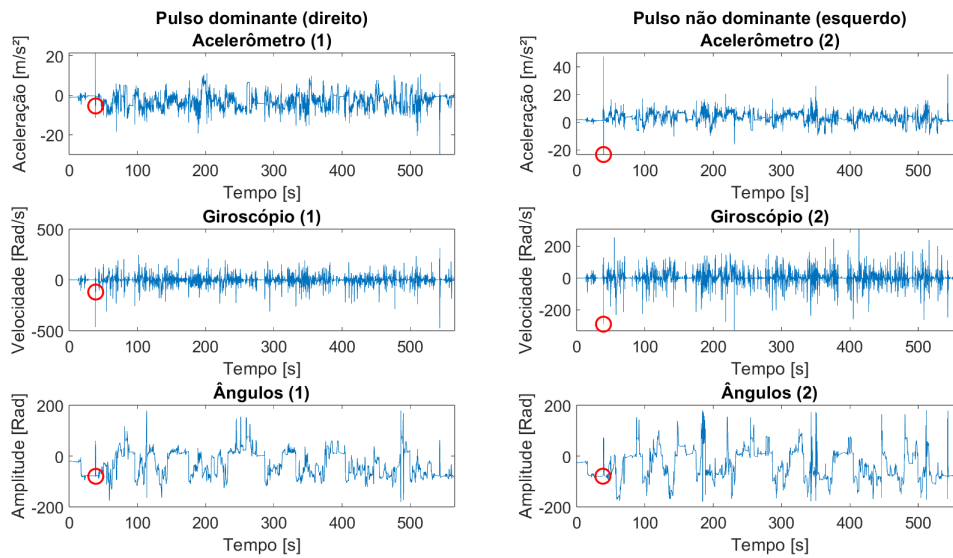
Nesta seção são apresentados os métodos e ferramentas para o pré-processamento e extração de características que foram utilizados previamente ao uso da rede neural para identificação das atividades monitoradas.

#### 3.3.1 Sincronização do vídeo e sensores

Quando é realizada a gravação de vídeos em conjunto com a utilização de sensores, como acelerômetros ou sensores inerciais, é fundamental que o tempo registrado em cada dispositivo esteja corretamente sincronizado. Para garantir uma sincronização precisa entre os dados capturados dos dispositivos, foi necessário realizar a calibração do tempo da gravação em vídeo com o tempo dos sensores.

Para isso, foi realizado a identificação de pontos de referência comuns nos sinais de vídeo e nos sinais dos sensores. Esses pontos foram gravados em vídeo como um estímulo externo, no caso, o bater de uma palma após o indivíduo manter-se parado por cerca de 10s. No sinal, um pico referente à esta ação de estímulo é gerado, o qual é identificado por meio de análise gráfica visual e marcado manualmente por um círculo vermelho, como ilustrado na Figura 16.

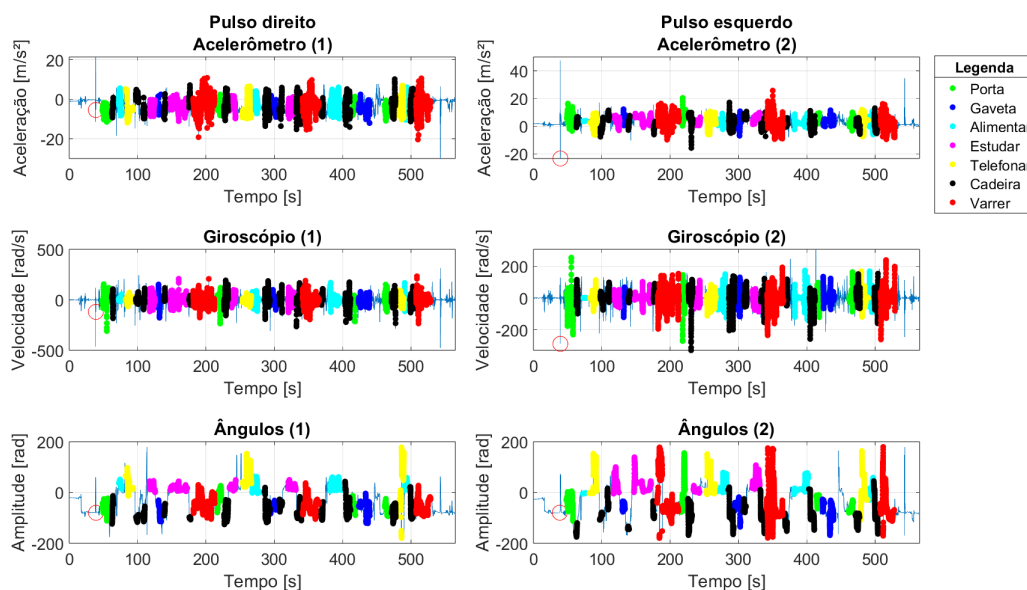
Figura 16 – Sincronização do tempo do vídeo com o tempo do sensor



Fonte: Autor.

Em seguida, para verificar se a sequência de movimentos está de acordo com o protocolo elaborado, por meio de um algoritmo simples, foi feita a conferência visual de modo que as ações realizadas durante a coleta não iriam sobrepor graficamente, veja a Figura 17, significando que os valores de início e término dos dados de referência seriam iguais para atividades distintas, com isso resultaria em maiores números de falsos positivos dos classificadores.

Figura 17 – Análise visual da coleta de dados



Fonte: Autor.

### 3.3.2 Sintetização dos dados

A finalidade de se aumentar o número de informações a partir dos dados disponíveis da coleta, é fornecer maiores variações que poderiam não ser possíveis na base de dados em uso, como por exemplo pequenas modificações de posicionamento dos sensores inercias, ou mesmo movimentações dos sensores em função da fisiologia de cada indivíduo para melhorar a homogeneidade amostral, tornando os dados destas amostras mais uniformes, visto que as atividades realizadas apresentam uma disparidade em relação ao tempo de execução de cada uma delas, tal como visto na Tabela 4.

Dessa forma, é proposto o aumento do número de dados com foco na melhoria de assimetria das amostras, sendo aumentado artificialmente somente as diferenças de assimetria, mantendo os dados reais inalterados, como visto em Krawczyk (2016). O fornecimento dos dados artificiais é realizado sobre cada janela de dados de  $260ms$  (ou 13 quadros), duplicando as amostras, empiricamente, após uma pequena rotação artificial dos sensores com ângulos aleatórios entre  $-3^\circ$  e  $+3^\circ$  para cada eixo, e modelada como  $S_{i_{R_{xyz}}} = R_{xyz}S_i$ , sendo a transformação das leituras do sensor  $S_i$ , para  $i = \{1, 2\}$ , promovida pela matriz  $R_{xyz}$  que define a sequência de rotação dos eixos  $x, y, e z$  respectivamente pelos ângulos  $\phi, \theta$  e  $\psi$ .

Assim, de posse os algoritmos de classificação e das técnicas de extração de característica apresentadas nas Seções 2.4 e 2.5 do Capítulo 2, propomos neste trabalho a escolha das seguintes características e informações dos sinais, considerando duas unidades de medida inercial, em recortes de  $260ms$  (13 quadros ou aprox.  $\frac{1}{4}FS$ ): janelamento de Hamming, banco de filtros, RMS, kurtosis, skewness e Distância de pico-a-pico. No total teremos 72 características por tipo de medida considerando os três eixos dos sensores (39 dados crús, 24 valores RMS, 3 valores de Kurtosis, 3 valores de Skewness e 3 distâncias de pico-a-pico, conforme ilustrado na Tabela 7, e como foram utilizados dados oriundos de acelerações, velocidades angulares e ângulos de orientação nas duas IMUs, totalizamos 432 características dos sinais, sendo representadas pela Tabela 8.

Tabela 7 – Quantidade de atributos extraídos do sinal

Características por sensor					
Tipos de atributos do sinal	Eixos			Qtd. total por atributo	Qtd. total
	X	Y	Z		
Dados crús	13	13	13	39	72
Banco de filtros	8	8	8	24	
<i>Kurtosis</i>	1	1	1	3	
<i>Skewness</i>	1	1	1	3	
Picos	1	1	1	3	

Fonte: Autor.

Tabela 8 – Todos os atributos utilizados no classificador *fine k-NN*

Descrição e posicionamento						
Tipo	Acel. 1	Giro. 1	Âng. 1	Acel. 2	Giro. 2	Âng. 2
Dados crús	1 - 39	145 - 183	289 - 327	73 - 111	217 - 255	361 - 399
Banco de filtros	40 - 63	184 - 207	328 - 351	112 - 135	256 - 279	400 - 423
<i>Kurtosis</i>	64 - 66	208 - 210	352 - 354	136 - 138	280 - 282	424 - 426
<i>Skewness</i>	67 - 69	211 - 213	355 - 357	139 - 141	283 - 285	427 - 429
Picos (máx-mín)	70 - 72	214 - 216	358 - 360	142 - 144	286 - 288	430 - 432

Fonte: Autor.

Entretanto, visando reduzir a dimensionalidade dos dados, testes foram realizados utilizando *Principal Component Analysis* (Análise de Componentes Principais) (PCA) e seleção de atributos. Em que o PCA configurado a 99% de representação dos dados, em que busca projetar os dados em um espaço de menor dimensão, capturando a maior variância possível. Já a seleção de atributos foi feita escolhendo os atributos mais relevantes e descartando os menos importantes de modo empírico, e avaliando o comportamento do classificador até a acurácia se manter estável em um range de 2%. Ambas as abordagens reduziram a dimensionalidade dos dados de maneira significativa, com isso simplificou o modelo e melhorou a eficiência computacional dos classificadores, como será discutido no Capítulo 4.

### 3.3.3 Rede Neural por Reconhecimento de Padrões

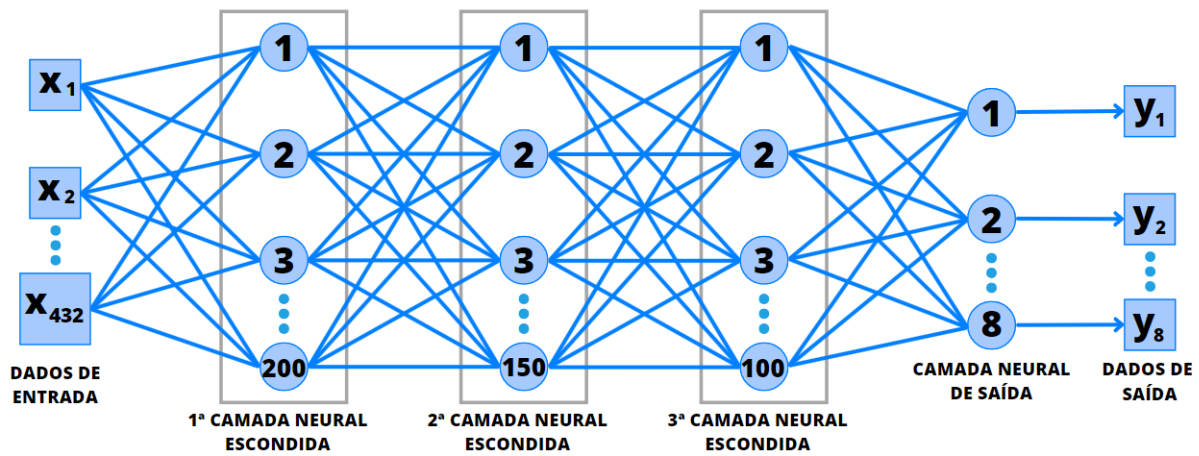
Após a escolha das características e informações, foi proposto o uso de dois tipos de classificadores em *Machine Learning*, sendo utilizada as aplicações NNPR e *Fine k-NN* do *Classification Learning*, ambas pertencentes ao *Toolbox Machine Learning and Deep Learning* do *Matlab*.

Este modelo de RNAs é uma rede de arquitetura *feedforward* multicamadas *Perceptron*, com algoritmo de aprendizagem *scaled conjugate gradient backpropagation* que, segundo Møller (1993), possui vantagens para problemas de otimização de larga escala, quando comparado com o algoritmo *backpropagation*, cuja efetividade depende dos parâmetros de ajuste da rede definidos pelo usuário.

A camada de entrada é responsável por utilizar a matriz de referência contendo os atributos como alimentação da rede neural. Nessa camada, são aplicadas funções de ativação do tipo sigmóide em seus neurônios, cuja quantidade é configurável de acordo com a especificação desejada. Além disso, a distribuição dos dados para teste, validação e treinamento é definida de acordo com a porcentagem estabelecida, onde amostras de teste e validação são selecionadas através da função *Data Division* no modo *Random* pelo algoritmo.

A camada de saída é composta por 8 neurônios que recebem os dados previamente treinados e são responsáveis por finalizar o processo de classificação. Esses 8 neurônios emitem os valores de saída predefinidos na matriz de referência, como ilustrado na Figura 18. Essa configuração da camada de saída permite que a rede neural seja capaz de realizar a classificação de maneira precisa e eficiente, produzindo os resultados desejados de acordo com os padrões estabelecidos na matriz de referência.

Figura 18 – Topologia da Rede Neural de Reconhecimento de Padrões utilizada.



Fonte: Autor.



---

# Capítulo 4

## Resultados

---

Neste capítulo serão discutidos os resultados das classificações feitas utilizando k-NN e NNPR. Na Seção 4.1 serão exibidos as identificações obtidas através de testes provenientes dos classificadores *Fine* k-NN, bem como os resultados e discussões. Do mesmo modo, na Seção 4.2, serão apresentados os resultados e discussões pertencentes aos testes em RNAs.

### 4.1 Fine k-Nearest Neighbors

Nesta seção, serão apresentados os cinco testes realizados, cada um com abordagens diferentes. O teste k-NN1 utilizou todas as 432 características disponíveis para treinar a rede. No teste k-NN2, aplicou-se o PCA com a descrição de 99% dos dados, resultando na redução das classes de 432 para 45. No teste k-NN3, desprezou-se os dados crus e manteve-se apenas os demais atributos. No teste k-NN4, realizou-se a seleção das características, buscando testar a sensibilidade do sistema, chegando-se a um total de 174 atributos de entrada.

Por fim, no teste k-NN5, manteve-se a mesma configuração do quarto teste, referente ao sensor 1, porém os dados fornecidos pelo sensor posicionado no membro não dominante (sensor 2) foram removidos, o que resultou em uma redução de 77.77% no número de dados de entrada. O detalhamento completo dos testes, juntamente com os resultados obtidos, são apresentados na Tabela 9, em que cada abordagem apresentou seus respectivos impactos nos resultados, permitindo assim elaborar uma análise mais abrangente sobre a eficácia e a robustez do sistema frente às diferentes configurações e condições de entrada.

Tabela 9 – Testes realizados com *Fine* k-NN

			PCA	Dados crus (RAW)	Banco de filtros	Kurtosis (Achatamento)	Skewness (Assimetria)	Picos(Max-min)	Acurácia média (%)	Qtd. atributos	Redução de dados (%)
k-NN1	S1	x		X	X	X	X	X	95.40	432	0.00
		y		X	X	X	X	X			
		z		X	X	X	X	X			
	S2	x		X	X	X	X	X			
		y		X	X	X	X	X			
		z		X	X	X	X	X			
k-NN2	S1	x	X	X	X	X	X	X	92.90	45	89.58
		y	X	X	X	X	X	X			
		z	X	X	X	X	X	X			
	S2	x	X	X	X	X	X	X			
		y	X	X	X	X	X	X			
		z	X	X	X	X	X	X			
k-NN3	S1	x			X	X	X	X	94.00	198	54.16
		y			X	X	X	X			
		z			X	X	X	X			
	S2	x			X	X	X	X			
		y			X	X	X	X			
		z			X	X	X	X			
k-NN4	S1	x			X	X	X		94.30	174	59.72
		y			X	X	X	X			
		z			X	X	X	X			
	S2	x									
		y				X	X				
		z									
k-NN5	S1	x			X	X	X		92.50	96	77.77
		y			X	X	X	X			
		z			X	X	X	X			
	S2	x									
		y									
		z									

Fonte: Autor.

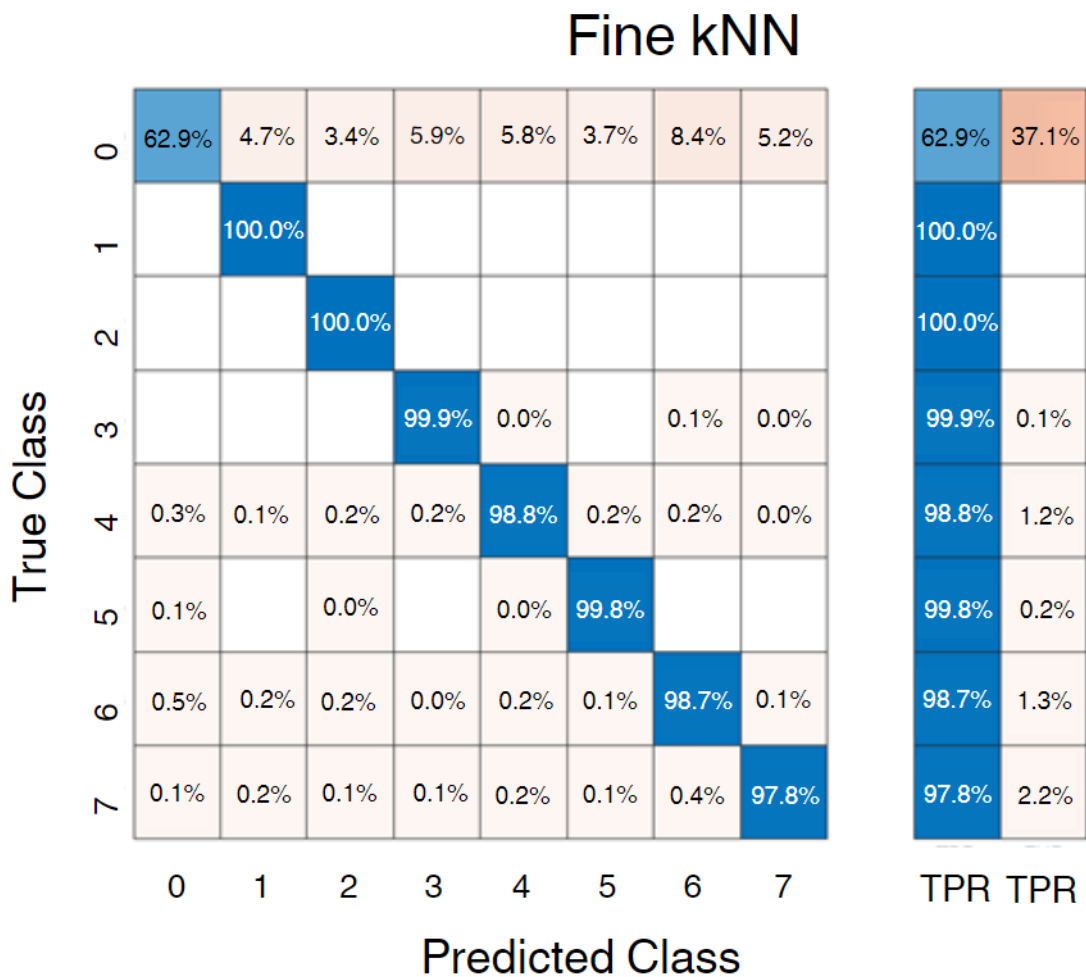
Conforme apresentado na Tabela 9, no teste k-NN2 houve-se uma redução de aproximadamente 89% no volume dos dados de entrada com PCA nas classificações, embora a acurácia tenha reduzido pouco mais de 2%, este ganho de processamento é relevante.

Ao realizar o teste k-NN 4, foi observado que o sensor 2, localizado no membro não

dominante, possui uma influência menor na estimativa das atividades. Isso ocorreu após a remoção de certos atributos específicos dos eixos, resultando em uma melhora na acurácia. Com base nessa constatação, decidiu-se conduzir o teste k-NN 5, excluindo os dados do sensor do membro não dominante (sensor 2).

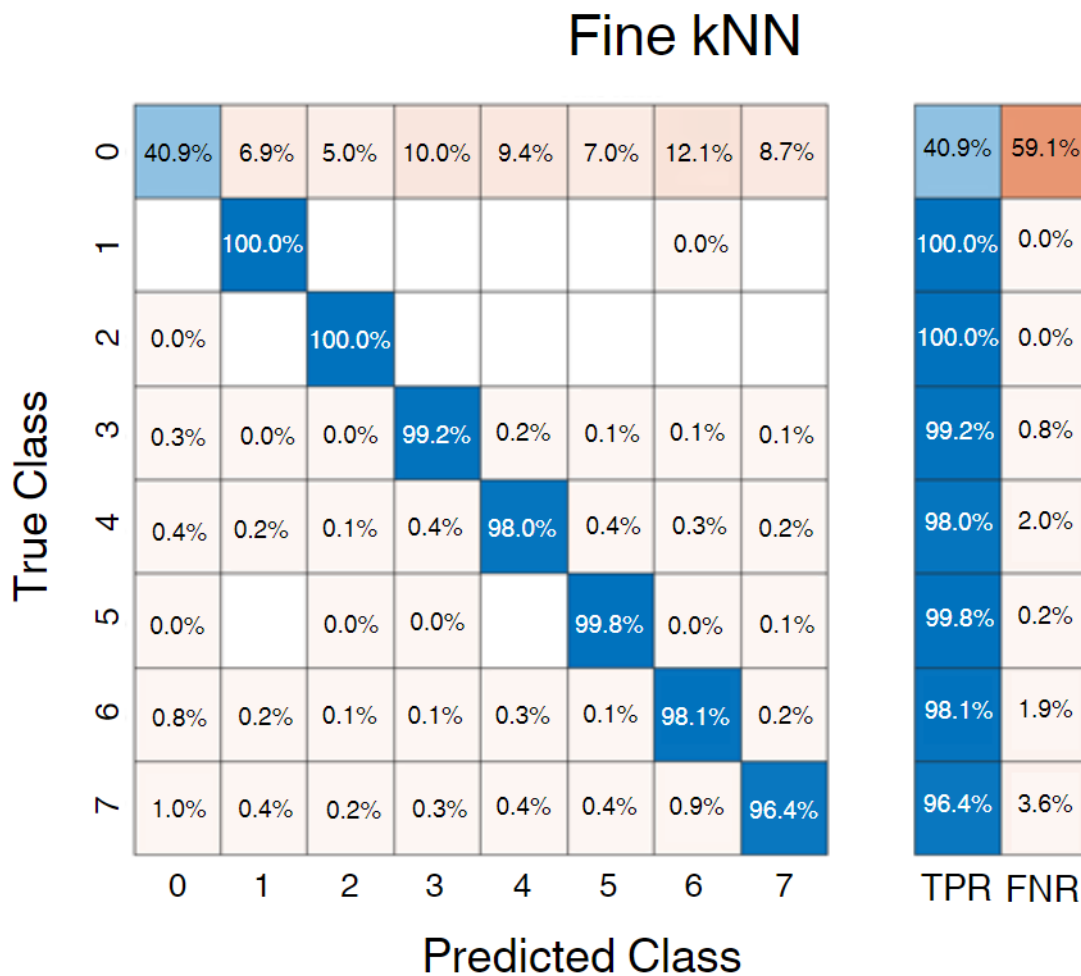
Ao comparar o teste k-NN1 com o teste k-NN 5, nota-se uma diminuição na acurácia média das classificações quando apenas os dados de um sensor são utilizados como entrada na rede (teste k-NN 5). Além disso, ao examinar individualmente cada classe de atividade identificada, a classificação revelou-se inferior quando comparada à utilização de dois sensores (teste k-NN1). Tal análise pode ser vista nas Figuras 19 e 20.

Figura 19 – Teste k-NN1



Fonte: Autor.

Figura 20 – Teste k-NN 5



Fonte: Autor.

Ou seja, a combinação de movimentos do membro dominante com o membro não dominante (NNPR 1) forneceu resultados significativamente melhores para as atividades; movimentos aleatórios, alimentar, estudo, cadeira e varrer, em comparação com o NNPR 5, que foi utilizado apenas o sensor posicionado no membro dominante (sensor 1).

## 4.2 Neural Nets Pattern Recognition (NNPR)

Nesta seção são apresentados os resultados dos 6 testes realizados com as redes *Neural Nets Pattern Recognition*, sendo o teste NNPR1 utilizando as 432 classes com 56298 amostras como entrada da rede e com a rede de apenas uma camada escondidas contendo 200 neurônios, parametrizadas em 70% para treinamento, 15% para teste e 15% para validação dos dados; o teste NNPR2 manteve as configurações do teste NNPR1, porém,

inclui-se uma segunda camada escondida com 150 neurônios; o teste NNPR3 manteve as configurações dos testes NNPR1 e NNPR2, e incluiu-se uma terceira camada com 100 neurônios; por fim, para os testes NNPR 4, NNPR5 e NNPR6, manteve-se as configurações da rede do teste NNPR3, utilizando como entrada da rede os atributos selecionados durante o teste k-NN4, descritos pela Tabela 9, sendo selecionadas as classes provenientes dos testes k-NN3, k-NN4 e k-NN5 realizados com o classificador *fine* k-NN, ou seja, 198 classes para o quinto teste, 174 classes para o sexto teste e 96 classes para o sétimo e último teste, tal como mostra a Tabela 10.

Tabela 10 – Testes realizados com NNPR

56298 amostras e 8 classes de saída						
	Treino Teste Validação (%)	Neurônios por camada			Classes entrada	Acurácia média (%)
	70 - 15 - 15	1	2	3		
<b>NNPR1</b>	X	200	N/A	N/A	432	89.9
<b>NNPR2</b>	X	200	150	N/A	432	96.7
<b>NNPR3</b>	X	200	150	100	432	96.9
<b>NNPR4</b>	X	200	150	100	198	94.1
<b>NNPR5</b>	X	200	150	100	174	91.3
<b>NNPR6</b>	X	200	150	100	96	88.7

Fonte: Autor

Após a realização dos testes verificou-se que iniciando com uma única camada escondida, observou-se que o desempenho do modelo de reconhecimento de padrões foi razoável. A rede neural foi capaz de aprender e identificar alguns padrões básicos, mas sua capacidade de generalização era limitada. A adição de mais camadas escondidas mostrou-se promissora para melhorar o desempenho. Com duas camadas escondidas, a primeira com 150 e a segunda com 200 neurônios, a rede neural teve uma maior capacidade de aprendizado, sendo capaz fornecer maiores números de acertos e generalizar melhor para dados de teste.

À medida que mais camadas escondidas foram adicionadas, a rede neural mostrou um aumento no poder de representação. Com três camadas escondidas, sendo a primeira com 200, a segunda com 150 e a terceira com 100 neurônios, a capacidade de aprendizado e generalização foi ainda mais aprimorada. A rede neural conseguiu capturar mais relações nos dados de treinamento, resultando em um desempenho mais preciso na identificação de padrões.

Em resumo, os testes realizados demonstraram que aumentar a profundidade e a largura da rede leva a uma melhoria no desempenho do modelo até um certo limite, ultra-

passando esse limiar, os avanços são mínimos e podem ser descartados. Nota-se que com apenas uma camada escondida a acurácia da rede reduz em quase 7%. Em contrapartida, para as demais classificações, obteve-se bons resultados, porém, é necessário considerar a relação entre a complexidade do modelo e o tempo de treinamento para que o custo computacional não seja elevado, tendo em vista que as redes contendo configurações menos robustas já demonstraram eficiência, como demonstrado pelas Figuras 21 e 22, resultados dos testes NNPR2 e NNPR3, respectivamente.

Figura 21 – Teste NNPR2

**Confusion Matrix**

1	5066 9.0%	30 0.1%	7 0.0%	68 0.1%	65 0.1%	17 0.0%	183 0.3%	60 0.1%	92.2% 7.8%
2	98 0.2%	7363 13.1%	2 0.0%	4 0.0%	1 0.0%	1 0.0%	7 0.0%	4 0.0%	98.4% 1.6%
3	82 0.1%	1 0.0%	7409 13.2%	38 0.1%	11 0.0%	1 0.0%	17 0.0%	17 0.0%	97.8% 2.2%
4	187 0.3%	11 0.0%	11 0.0%	7052 12.5%	32 0.1%	4 0.0%	31 0.1%	9 0.0%	96.1% 3.9%
5	122 0.2%	4 0.0%	1 0.0%	18 0.0%	6891 12.2%	3 0.0%	18 0.0%	10 0.0%	97.5% 2.5%
6	86 0.2%	1 0.0%	0 0.0%	9 0.0%	5 0.0%	6829 12.1%	12 0.0%	9 0.0%	98.2% 1.8%
7	289 0.5%	9 0.0%	8 0.0%	9 0.0%	10 0.0%	6 0.0%	6982 12.4%	21 0.0%	95.2% 4.8%
8	174 0.3%	3 0.0%	3 0.0%	5 0.0%	8 0.0%	1 0.0%	18 0.0%	6845 12.2%	97.0% 3.0%
	83.0% 17.0%	99.2% 0.8%	99.6% 0.4%	97.9% 2.1%	98.1% 1.9%	99.5% 0.5%	96.1% 3.9%	98.1% 1.9%	96.7% 3.3%
	1	2	3	4	5	6	7	8	
	<b>Target Class</b>								

Fonte: Autor.

Figura 22 – Teste NNPR3

**Confusion Matrix**

1	5089 8.9%	22 0.0%	6 0.0%	46 0.1%	35 0.1%	14 0.0%	147 0.3%	54 0.1%	94.0% 6.0%
2	113 0.2%	7509 13.1%	10 0.0%	7 0.0%	0 0.0%	1 0.0%	16 0.0%	16 0.0%	97.9% 2.1%
3	78 0.1%	2 0.0%	7612 13.3%	24 0.0%	6 0.0%	1 0.0%	16 0.0%	8 0.0%	98.3% 1.7%
4	163 0.3%	2 0.0%	3 0.0%	7073 12.3%	31 0.1%	3 0.0%	20 0.0%	7 0.0%	96.9% 3.1%
5	158 0.3%	1 0.0%	0 0.0%	31 0.1%	7428 13.0%	5 0.0%	18 0.0%	12 0.0%	97.1% 2.9%
6	99 0.2%	1 0.0%	0 0.0%	14 0.0%	14 0.0%	6993 12.2%	12 0.0%	7 0.0%	97.9% 2.1%
7	262 0.5%	4 0.0%	7 0.0%	6 0.0%	16 0.0%	11 0.0%	6701 11.7%	15 0.0%	95.4% 4.6%
8	156 0.3%	7 0.0%	2 0.0%	2 0.0%	10 0.0%	3 0.0%	27 0.0%	7186 12.5%	97.2% 2.8%
	83.2% 16.8%	99.5% 0.5%	99.6% 0.4%	98.2% 1.8%	98.5% 1.5%	99.5% 0.5%	96.3% 3.7%	98.4% 1.6%	96.9% 3.1%
	1	2	3	4	5	6	7	8	
	<b>Target Class</b>								

Fonte: Autor.

Assim, nota-se que a configuração da rede mais apropriada para executar esta tarefa seria a estabelecida pelo teste k-NN2, uma vez que demonstrou boa precisão, sendo apenas 0,2% inferior ao teste k-NN3. Além disso, o tempo de convergência do algoritmo do teste k-NN2 também foi menor em comparação ao teste k-NN3, resultando em uma redução significativa no processamento dos dados.

Esses resultados evidenciam que a rede com duas camadas escondidas é capaz de reconhecer as classes de atividades com menor necessidade de capacidade de processamento. Essa característica pode ser atribuída ao fato de que, a partir de redes com três camadas escondidas, a precisão se estabilizou em 96,9%. Em outras palavras, à medida que aumenta o número de camadas escondidas, ocorre um aumento na exigência computacional do sistema, o que não é necessário.





---

## Capítulo 5

### Conclusão

---

Com base nos resultados das classificações realizadas na plataforma proposta, foi observado que os movimentos definidos como "atividade 0", representando os períodos de inatividade ou movimentos não monitorados, apresentaram maior dificuldade de identificação. Isso ocorreu devido à grande oscilação de gestos durante esses períodos, o que gerou confusões e desafios para os classificadores. No entanto, após a sintetização dos dados e a obtenção de conjuntos amostrais mais uniformes, foi possível reduzir os erros decorrentes dessas confusões de classes, contribuindo para melhorar a capacidade de identificação das atividades de inatividade. Essa análise reforça a importância de aprimorar os algoritmos de classificação para lidar com a complexidade dos gestos durante os períodos de inatividade.

Com o algoritmo *Fine k-Nearest Neighbor* (k-NN), foi possível alcançar a acurácia mais elevada de 95,4% ao utilizar todos os dados como parâmetros de entrada do classificador. No entanto, ao selecionar atributos específicos do sinal, foi possível reduzir a dimensionalidade dos dados em cerca de 60,0%, mantendo uma assertividade de 94,3%. A maior redução de dimensionalidade, no entanto, foi obtida no teste k-NN2 através da utilização do PCA, alcançando 89,5% de diminuição. É importante ressaltar que, apesar da alta redução de dimensionalidade, esse método apresentou a segunda pior acurácia, ficando apenas à frente do teste k-NN5, no qual os dados do sensor 2 não foram utilizados. Isso evidencia que, para identificar as 7 atividades cotidianas propostas quando realizadas por indivíduos saudáveis, a utilização de dois sensores (um em cada membro superior) contribui para obter classificações mais satisfatórias.

Ademais, a implementação dos algoritmos em Reconhecimento de Padrões por Redes Neurais resultou em acurácias equivalentes aos algoritmos de k-NN, com o teste NNPR3 sendo o mais assertivo, atingindo assertividade de 96,9%, ou seja, pouco mais de 2% em

comparação ao resultado mais expressivo de k-NN obtido pelo teste k-NN1 para classificar as 7 atividades propostas. Os testes para diminuir o custo computacional possibilitaram reduzir a quantidade de dados de 432 para 174, mantendo uma taxa superior a 90% de assertividade. Similarmente ao k-NN, os resultados dos testes sem o uso do segundo sensor foram piores em comparação à utilização dos dois sensores, resultando em uma redução na acurácia para 88,7%.

O aplicativo desenvolvido para aquisição e armazenamento dos dados de coleta funcionou de maneira satisfatória, permitindo que os dados fossem armazenados na nuvem. Isso facilitou o acesso remoto e o tratamento dos dados, eliminando a dependência de dispositivos físicos para transferência de dados.

A técnica de aumento de dados via rotação randomizada tornou as amostras de dados mais robustas em termos quantitativos, preservando a natureza dos movimentos executados. Isso contribuiu para que os modelos de classificação generalizassem melhor as classes durante o processo de reconhecimento, resultando em um alto nível de acurácia em comparação aos dados não sintetizados. Essa abordagem se mostrou eficaz para melhorar a capacidade de generalização dos modelos e manter um desempenho preciso de classificação.

Para aprofundar a compreensão dos procedimentos propostos, são necessários estudos futuros que avaliem essas abordagens em conjuntos de dados mais extensos, abrangendo uma variedade de atividades cotidianas dos membros superiores. Essas atividades podem incluir, por exemplo, vestir/retirar agasalhos, abrir/ fechar zíper de calça ou blusa, tirar/colocar meias e sapatos, amarrar e desamarrar os cadarços dos sapatos, alcançar objetos em diferentes alturas e pentear o cabelo. Essas investigações são importantes para determinar se o sensor posicionado no membro não dominante pode fornecer parâmetros satisfatórios para contribuir na classificação precisa de atividades cotidianas executadas por indivíduos saudáveis, bem como fornecer parâmetros mais robustos para monitorar as atividades de reabilitação de pacientes pós-AVC.

---

## Referências

---

Academia Brasileira de Neurologia (ABNEURO). **Proporção de jovens que morrem de Acidente Vascular Cerebral (AVC) no Brasil aumenta em 2021**. 2021. Disponível em: <<https://www.abneuro.org.br/2021/11/01/proporcao-de-jovens-que-morrem-de-avc-no-brasil-aumenta-em-2021-veja-sintomas/>>. Acesso em: 15 de maio de 2023.

\_\_\_\_\_. **Acidente Vascular Cerebral - (AVC)**. 2023. Disponível em: <<https://www.abneuro.org.br/>>. Acesso em: 15 de maio de 2023.

ALARCÓN, F. et al. Post-stroke movement disorders: report of 56 patients. **Journal of neurology, neurosurgery and psychiatry**, BMJ Publishing Group Ltd, London, v. 75, n. 11, p. 1568–1574, 2004. ISSN 0022-3050.

ANJOS, S. M. dos et al. Reliability and validity of the lower extremity motor activity log for measuring real-world leg use in adults with multiple sclerosis. **Archives of physical medicine and rehabilitation**, Elsevier Inc, United States, v. 102, n. 4, p. 626–632, 2021. ISSN 0003-9993.

Annabel McDermott. **Acidente Vascular Cerebral - (AVC)**. 2023. Disponível em: <<https://strokengine.ca/en/assessments/motor-activity-log-mal/>>. Acesso em: 15 de maio de 2023.

ANTUVAN, C. W. et al. Role of muscle synergies in real-time classification of upper limb motions using extreme learning machines. **Journal of NeuroEngineering and Rehabilitation**, v. 13, n. 1, p. 76, dez. 2016. ISSN 1743-0003. Disponível em: <<http://jneuroengrehab.biomedcentral.com/articles/10.1186/s12984-016-0183-0>>.

AU, S.; DILWORTH, P.; HERR, H. An ankle-foot emulation system for the study of human walking biomechanics. In: **Proceedings 2006 IEEE International Conference on Robotics and Automation, 2006. ICRA 2006**. [S.l.: s.n.], 2006. p. 2939–2945. ISSN: 1050-4729.

BENSENOR, I. M. et al. Prevalence of stroke and associated disability in brazil. **Arquivos de Neuro-Psiquiatria**, v. 73, n. 9, p. 746–750, set. 2015. ISSN 0004-282X. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0004-282X2015000900746&lng=en&tlng=en](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0004-282X2015000900746&lng=en&tlng=en)>.

- BERNAL, V. C. E. et al. Classifying and tracking rehabilitation interventions through machine-learning algorithms in individuals with stroke. **Journal of Rehabilitation and Assistive Technologies Engineering**, v. 8, p. 205566832110446, jan. 2021. ISSN 2055-6683, 2055-6683.
- Biblioteca Virtual em Saúde - Ministério da Saúde. **Acidente Vascular Cerebral (AVC)**. 2015. Disponível em: <<https://bvsmms.saude.gov.br/avc-acidente-vascular-cerebral/>>. Acesso em: 17 de maio de 2023.
- BRATAN, T.; CLARKE, M. Optimum design of remote patient monitoring systems. **2006 International Conference of the IEEE Engineering in Medicine and Biology Society**, IEEE, p. 6465–6468, 2006. ISSN 1557-170X.
- BURNS, A.; ADELI, H.; BUFORD, J. A. Upper limb movement classification via electromyographic signals and an enhanced probabilistic network. **Journal of Medical Systems**, v. 44, n. 10, p. 176, out. 2020. ISSN 0148-5598, 1573-689X. Disponível em: <<https://link.springer.com/10.1007/s10916-020-01639-x>>.
- CHA, J. et al. Development of the korean medicine core outcome set for stroke sequelae: Herbal medicine treatment of elderly patients with stroke sequelae in primary clinics. **Frontiers in Pharmacology**, Frontiers Media SA, v. 13, apr 2022.
- CHAE, S. H. et al. Development and Clinical Evaluation of a Web-Based Upper Limb Home Rehabilitation System Using a Smartwatch and Machine Learning Model for Chronic Stroke Survivors: Prospective Comparative Study. **JMIR mHealth and uHealth**, v. 8, n. 7, p. e17216, jul. 2020. ISSN 2291-5222. Disponível em: <<http://mhealth.jmir.org/2020/7/e17216/>>.
- CHEN, T. et al. Long-term unmet needs after stroke: systematic review of evidence from survey studies. **BMJ Open**, BMJ, v. 9, n. 5, p. e028137, may 2019.
- CUI, J.-W. et al. Recognition of upper limb action intention based on imu. **Sensors**, v. 22, n. 5, p. 1954, jan. 2022. ISSN 1424-8220. Number: 5 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/22/5/1954>>.
- DA-SILVA, R. H. et al. Prompting arm activity after stroke: A clinical proof of concept study of wrist-worn accelerometers with a vibrating alert function. **Journal of Rehabilitation and Assistive Technologies Engineering**, SAGE Publications, v. 5, p. 205566831876152, jan 2018.
- DALEY, K.; MAYO, N.; WOOD-DAUPHINÉE, S. Reliability of Scores on the Stroke Rehabilitation Assessment of Movement (STREAM) Measure. **Physical Therapy**, v. 79, n. 1, p. 8–23, 01 1999. ISSN 0031-9023. Disponível em: <<https://doi.org/10.1093/ptj/79.1.8>>.
- DOMAN, C. A. et al. Changes in upper-extremity functional capacity and daily performance during outpatient occupational therapy for people with stroke. **The American Journal of Occupational Therapy**, AOTA Press, v. 70, n. 3, p. 7003290040p1–7003290040p11, apr 2016.
- DUNCAN, P. W. et al. Management of adult stroke rehabilitation care: a clinical practice guideline. **Stroke (1970)**, United States, v. 36, n. 9, p. e100–e143, 2005. ISSN 0039-2499.

ERMES, M. et al. Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions. **IEEE Transactions on Information Technology in Biomedicine**, Institute of Electrical and Electronics Engineers (IEEE), v. 12, n. 1, p. 20–26, jan 2008.

FEIGIN, V. L. et al. Global, regional, and national burden of stroke and its risk factors, 1990–2019: a systematic analysis for the Global Burden of Disease Study 2019. **The Lancet Neurology**, v. 20, n. 10, p. 795–820, out. 2021. ISSN 14744422. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1474442221002520>>.

\_\_\_\_\_. The global burden of neurological disorders: translating evidence into policy. **The Lancet Neurology**, v. 19, n. 3, p. 255–265, mar. 2020. ISSN 14744422. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1474442219304119>>.

FILIPPESCHI, A. et al. Survey of motion tracking methods based on inertial sensors: A focus on upper limb human motion. **Sensors**, v. 17, n. 6, p. 1257, jun. 2017. ISSN 1424-8220. Number: 6 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/17/6/1257>>.

FRANCELINO, E. et al. Markov system with self-aligning joint constraint to estimate attitude and joint angles between two consecutive segments. **Journal of Intelligent & Robotic Systems**, v. 104, n. 3, p. 43, mar. 2022. ISSN 0921-0296, 1573-0409. Disponível em: <<https://link.springer.com/10.1007/s10846-022-01572-w>>.

GAVRILA, D.; DAVIS, L. 3-D model-based tracking of humans in action: a multi-view approach. In: **Proceedings CVPR IEEE Computer Society Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 1996. p. 73–80. ISSN: 1063-6919.

HAQ, E. U. et al. Human detection and tracking with deep convolutional neural networks under the constrained of noise and occluded scenes. **Multimedia Tools and Applications**, v. 79, n. 41, p. 30685–30708, nov. 2020. ISSN 1573-7721. Disponível em: <<https://doi.org/10.1007/s11042-020-09579-x>>.

HATZE, H. Quantitative analysis, synthesis and optimization of human motion. **Human Movement Science**, v. 3, n. 1-2, p. 5–25, mar. 1984. ISSN 01679457. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/0167945784900034>>.

HENSLEY, C. P. et al. Reliability and validity of 2-dimensional video analysis for a running task: A systematic review. **Physical therapy in sport**, Elsevier Limited, Kidlington, v. 58, p. 16–33, 2022. ISSN 1466-853X.

KRAWCZYK, B. Learning from imbalanced data: open challenges and future directions. **Progress in Artificial Intelligence**, Springer Science and Business Media LLC, v. 5, n. 4, p. 221–232, apr 2016.

LANGHORNE, P.; COUPAR, F.; POLLOCK, A. Motor recovery after stroke: a systematic review. **The Lancet Neurology**, Elsevier BV, v. 8, n. 8, p. 741–754, aug 2009.

LEE, J. H. van der et al. Clinimetric properties of the motor activity log for the assessment of arm use in hemiparetic patients. **Stroke (1970)**, Lippincott Williams Wilkins, PHILADELPHIA, v. 35, n. 6, p. 1410–1414, 2004. ISSN 0039-2499.

LEONG, S. C. et al. Examining the effectiveness of virtual, augmented, and mixed reality (VAMR) therapy for upper limb recovery and activities of daily living in stroke patients: a systematic review and meta-analysis. **Journal of NeuroEngineering and Rehabilitation**, Springer Science and Business Media LLC, v. 19, n. 1, aug 2022.

LIN, W.-Y. et al. Predicting post-stroke activities of daily living through a machine learning-based approach on initiating rehabilitation. **International Journal of Medical Informatics**, v. 111, p. 159–164, mar. 2018. ISSN 13865056. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1386505618300029>>.

LIU, Q. et al. A fully connected deep learning approach to upper limb gesture recognition in a secure FES rehabilitation environment. **International Journal of Intelligent Systems**, v. 36, n. 5, p. 2387–2411, 2021. ISSN 1098-111X.   
\_eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/int.22383>. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/int.22383>>.

\_\_\_\_\_. Feature extraction and classification algorithm, which one is more essential? an experimental study on a specific task of vibration signal diagnosis. **International Journal of Machine Learning and Cybernetics**, v. 13, n. 6, p. 1685–1696, jun. 2022. ISSN 1868-8071, 1868-808X. Disponível em: <<https://link.springer.com/10.1007/s13042-021-01477-4>>.

LUM, P. et al. Quantification of force abnormalities during passive and active-assisted upper-limb reaching movements in post-stroke hemiparesis. **IEEE transactions on biomedical engineering**, IEEE, PISCATAWAY, v. 46, n. 6, p. 652–662, 1999. ISSN 0018-9294.

MACLACHLAN, M. et al. Assistive technology policy: a position paper from the first global research, innovation, and education on assistive technology (great) summit. **Disability and Rehabilitation. Assistive Technology**, v. 13, n. 5, p. 454–466, jul. 2018. ISSN 1748-3115.

MAJUMDER, S.; KEHTARNAVAZ, N. Vision and Inertial Sensing Fusion for Human Action Recognition: A Review. **IEEE Sensors Journal**, v. 21, n. 3, p. 2454–2467, fev. 2021. ISSN 1530-437X, 1558-1748, 2379-9153. Disponível em: <<https://ieeexplore.ieee.org/document/9187232/>>.

MARTINDALE, C. F. et al. Wearables-based multi-task gait and activity segmentation using recurrent neural networks. **Neurocomputing**, v. 432, p. 250–261, abr. 2021. ISSN 09252312. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0925231220317707>>.

MARTINS, M. et al. A review of the functionalities of smart walkers. **Medical engineering physics**, Elsevier Ltd, OXFORD, v. 37, n. 10, p. 917–928, 2015. ISSN 1350-4533.

MARTINS, M. M. et al. Assistive mobility devices focusing on smart walkers: Classification and review. **Robotics and autonomous systems**, Elsevier B.V, AMSTERDAM, v. 60, n. 4, p. 548–562, 2012. ISSN 0921-8890.

MILLER, A. et al. Comparison of Machine Learning approaches for Classifying Upper Extremity Tasks in Individuals Post-Stroke. **Annual International Conference of**

the **IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference**, v. 2020, p. 4330–4336, jul. 2020. ISSN 2694-0604.

MØLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural Networks**, Elsevier BV, v. 6, n. 4, p. 525–533, jan 1993.

MONT, D. et al. Assistive technology during the covid-19 global pandemic: The roles of government and civil society in fulfilling the social contract. **International Journal of Environmental Research and Public Health**, v. 18, n. 22, p. 12031, jan. 2021. ISSN 1660-4601. Number: 22 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1660-4601/18/22/12031>>.

MORITA, T. et al. BLE beacon-based activity monitoring system toward automatic generation of daily report. In: **2018 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)**. [S.l.]: IEEE, 2018.

NOGUEIRA, S. et al. Markov jump linear systems-based position estimation for lower limb exoskeletons. **Sensors**, MDPI AG, v. 14, n. 1, p. 1835–1849, jan 2014.

OFLI, F. et al. Sequence of the most informative joints (smij): A new representation for human skeletal action recognition. **Journal of Visual Communication and Image Representation**, v. 25, n. 1, p. 24–38, jan. 2014. ISSN 10473203. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1047320313000680>>.

OLIVEIRA, S. G. et al. Concurrent validity and reliability of an activity monitoring for rehabilitation (amor) platform for step counting and sitting/lying time in post-stroke individuals. **Topics in Stroke Rehabilitation**, v. 29, n. 2, p. 103–113, fev. 2022. ISSN 1074-9357, 1945-5119. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/10749357.2021.1886639>>.

OLIVEIRA, S. G. de. **Intervenções para mudança do comportamento de movimento e o desenvolvimento de uma plataforma para o monitoramento de atividade em reabilitação (MARe) para indivíduos pós acidente vascular cerebral**. Tese (Doutorado) — Universidade Federal de São Carlos (UFSCar), 2023.

Organização Mundial de Saúde. **From Burden to “Best Buys”: Reducing the Economic Impact of Non-Communicable Diseases in Low- and Middle-Income Countries**. 2011. Disponível em: <[https://ncdalliance.org/sites/default/files/resource\\_files/WHO%20From%20Burden%20to%20Best%20Buys.pdf](https://ncdalliance.org/sites/default/files/resource_files/WHO%20From%20Burden%20to%20Best%20Buys.pdf)>. Acesso em: 22 de maio de 2023.

OTEBOLAKU, A. et al. Deep Sensing: Inertial and Ambient Sensing for Activity Context Recognition Using Deep Convolutional Neural Networks. **Sensors**, v. 20, n. 13, p. 3803, jan. 2020. ISSN 1424-8220. Number: 13 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/20/13/3803>>.

PANWAR, M. et al. Rehab-Net: Deep Learning Framework for Arm Movement Classification Using Wearable Sensors for Stroke Rehabilitation. **IEEE Transactions on Biomedical Engineering**, v. 66, n. 11, p. 3026–3037, nov. 2019. ISSN 1558-2531. Conference Name: IEEE Transactions on Biomedical Engineering.

POHL, J. et al. Classification of functional and non-functional arm use by inertial measurement units in individuals with upper limb impairment after stroke. **Frontiers in Physiology**, Frontiers Media SA, v. 13, sep 2022.

PREECE, S. J. et al. Activity identification using body-mounted sensors—a review of classification techniques. **Physiological Measurement**, v. 30, n. 4, p. R1–R33, abr. 2009. ISSN 0967-3334, 1361-6579. Disponível em: <<https://iopscience.iop.org/article/10.1088/0967-3334/30/4/R01>>.

\_\_\_\_\_. A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data. **IEEE Transactions on Biomedical Engineering**, v. 56, n. 3, p. 871–879, mar. 2009. ISSN 0018-9294, 1558-2531. Disponível em: <<https://ieeexplore.ieee.org/document/4663615/>>.

RAMEY, M.; YANG, A. A simulation procedure for human motion studies. **Journal of Biomechanics**, v. 14, n. 4, p. 203–213, jan. 1981. ISSN 00219290. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/0021929081900658>>.

RICHARDS, L. G. et al. Movement-dependent stroke recovery: A systematic review and meta-analysis of tms and fmri evidence. **Neuropsychologia**, Elsevier Ltd, Oxford, v. 46, n. 1, p. 3–11, 2008. ISSN 0028-3932.

SHENG, Y. et al. Upper limb motor function quantification in post-stroke rehabilitation using muscle synergy space model. **IEEE Transactions on Biomedical Engineering**, p. 1–1, 2022. ISSN 0018-9294. Conference Name: IEEE Transactions on Biomedical Engineering.

SYED, U. A.; KAUSAR, Z.; SATTAR, N. Y. Upper limb motion detection using deep neural network. In: **2021 International Conference on Robotics and Automation in Industry (ICRAI)**. [S.l.: s.n.], 2021. p. 1–6.

SZCZESNA, A.; BŁASZCZYSZYN, M.; KAWALA-STERNIUK, A. Convolutional neural network in upper limb functional motion analysis after stroke. **PeerJ**, v. 8, p. e10124, out. 2020. ISSN 2167-8359. Publisher: PeerJ Inc. Disponível em: <<https://peerj.com/articles/10124>>.

TAO, W. et al. Worker activity recognition in smart manufacturing using IMU and sEMG signals with convolutional neural networks. **Procedia Manufacturing**, Elsevier BV, v. 26, p. 1159–1166, 2018.

TAUB, E. et al. Motor Activity Log (MAL) - 30. p. 18, 2011.

THARWAT, A. et al. Recognizing human activity in mobile crowdsensing environment using optimized k-n algorithm. **Expert Systems with Applications**, v. 107, p. 32–44, out. 2018. ISSN 09574174. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0957417418302471>>.

THURSTON, A. J. Giovanni borelli and the study of human movement: An historical review. **Australian and New Zealand Journal of Surgery**, Blackwell Publishing, Melbourne, Australia, v. 69, n. 4, p. 276–288, 1999. ISSN 0004-8682.



TURAGA, P. et al. Machine recognition of human activities: A survey. **IEEE Transactions on Circuits and Systems for Video Technology**, v. 18, n. 11, p. 1473–1488, nov. 2008. ISSN 1558-2205. Conference Name: IEEE Transactions on Circuits and Systems for Video Technology.

VASCULAR.PRO. **Acidente Vascular Cerebral (AVC)**. 2023. Disponível em: <<https://vascular.pro/acidente-vascular-cerebral-avc/>>. Acesso em: 22 de maio de 2023.

WINCKEL, A. Van de; GAUTHIER, L. A revised motor activity log following rasch validation (rasch-based mal-18) and consensus methods in chronic stroke and multiple sclerosis. **Neurorehabilitation and neural repair**, SAGE Publications, Los Angeles, CA, v. 33, n. 10, p. 787–791, 2019. ISSN 1545-9683.

Wit Motion. **WT901BLECL BLE 5.0 - User Manual**. 2023. Disponível em: <<https://www.wit-motion.com/digital-inclinometer/witmotion-wt901c-ttl-9-axis-imu-sensor.html>>. Acesso em: 15 de maio de 2023.

XIE, Y. et al. Generative learning for imbalanced data using the gaussian mixed model. **Applied Soft Computing**, Elsevier BV, v. 79, p. 439–451, jun 2019.

YANG, H. et al. MPJA-HAD: A multi-position joint angle dataset for human activity recognition using wearable sensors. In: **2022 International Conference on Advanced Mechatronic Systems (ICAMechS)**. [S.l.]: IEEE, 2022.

ZABAT, M. et al. Imu-based sensor-to-segment multiple calibration for upper limb joint angle measurement—a proof of concept. **Medical & Biological Engineering & Computing**, v. 57, n. 11, p. 2449–2460, nov. 2019. ISSN 0140-0118. Disponível em: <<https://doi.org/10.1007/s11517-019-02033-7>>.

ZHOU, H.; HU, H. Human motion tracking for rehabilitation—a survey. **Biomedical signal processing and control**, Elsevier, v. 3, n. 1, p. 1–18, 2008.

ZHOU, X. et al. Deep-learning-enhanced human activity recognition for internet of healthcare things. **IEEE Internet of Things Journal**, Institute of Electrical and Electronics Engineers (IEEE), v. 7, n. 7, p. 6429–6438, jul 2020.



---

# APÊNDICE A

## Câmera de vídeo

---

Figura 23 – Câmera utilizada para análise visual.



Fonte: Autor.



---

# APÊNDICE B

## Sensores Inerciais

---

Tabela 11 – Endereçamento local dos sensores.

Endereço MAC	
IMU do pulso esquerdo	IMU do pulso direito
C6:A9:4E:BC:45:1E	CE:79:1C:CD:27:81

Fonte: Autor.

Figura 24 – Sensores WitMotion.



Fonte: Autor.

Tabela 12 – Configurações do fabricante.

<b>Especificações técnicas</b>	
<b>Corrente</b>	<40mA.
<b>Tensão de entrada</b>	5Vcc.
<b>Frequência de saída</b>	0.2 - 200Hz.
<b>Ajuste de transmissão</b>	4800 - 961200.
<b>Dados de saída</b>	Aceleração triaxial; Ângulos; Velocidade angular.
<b>Range</b>	Aceleração $\pm 6g$ ; Giroscópio $\pm 2000^\circ$ . Ângulos (eixos X e Z $\pm 180^\circ$ e Y $\pm 90^\circ$ ).
<b>Resolução</b>	Aceleração (0.005g); Giroscópio ( $0.61^\circ/s$ ).
<b>Precisão angular</b>	Entre os eixos X e Y, sendo: 0.05° estático e 0.1° em movimento.

Fonte: Adaptada de (Wit Motion, 2023).

---

# APÊNDICE C

## Lista de verificação

---

Figura 25 – Protocolo de verificação pré-coleta.

**CHECK-LIST: Leia atentamente todos os itens.**

<input type="checkbox"/>	1-) Verificar se as condições do ambiente em que será realizada a coleta está adequado, sem obstáculos e funcionando.
<input type="checkbox"/>	2-) Verificar se o voluntário compreendeu as atividades pré-definidas que serão realizadas durante a coleta de dados.
<input type="checkbox"/>	3-) Padronizar o posicionamento do sensor no punho para todas as coletas (sensor sempre na mesma posição).
<input type="checkbox"/>	4-) Verificar se o celular está com a bateria acima de 80%.
<input type="checkbox"/>	5-) Verificar se o app "Stay Awake", está ativo. Disponível em: <a href="https://play.google.com/store/apps/details?id=org.hatapps.stayawake">https://play.google.com/store/apps/details?id=org.hatapps.stayawake</a> .
<input type="checkbox"/>	6-) Verificar se o sensor está com carga.
<input type="checkbox"/>	7-) Verificar se o app "BSL Capture UFSCar" reconhece o sensor.
<input type="checkbox"/>	8-) Verificar se o app "BSL Capture UFSCar" capta os sinais (em tempo real) emitidos pelo sensor, se estiver com zeros em x, y e z, feche o App, abra novamente e reconecte seguindo o tutorial de instalação, disponível em: <a href="https://youtu.be/FZdoMiacdCU">https://youtu.be/FZdoMiacdCU</a> .
<input type="checkbox"/>	9-) Verificar se o nome do arquivo está correto pra evitar erro na execução do código do Matlab.
<input type="checkbox"/>	10-) Conferir novamente a conexão bluetooth entre app e sensor.

**Iniciar a coleta.**



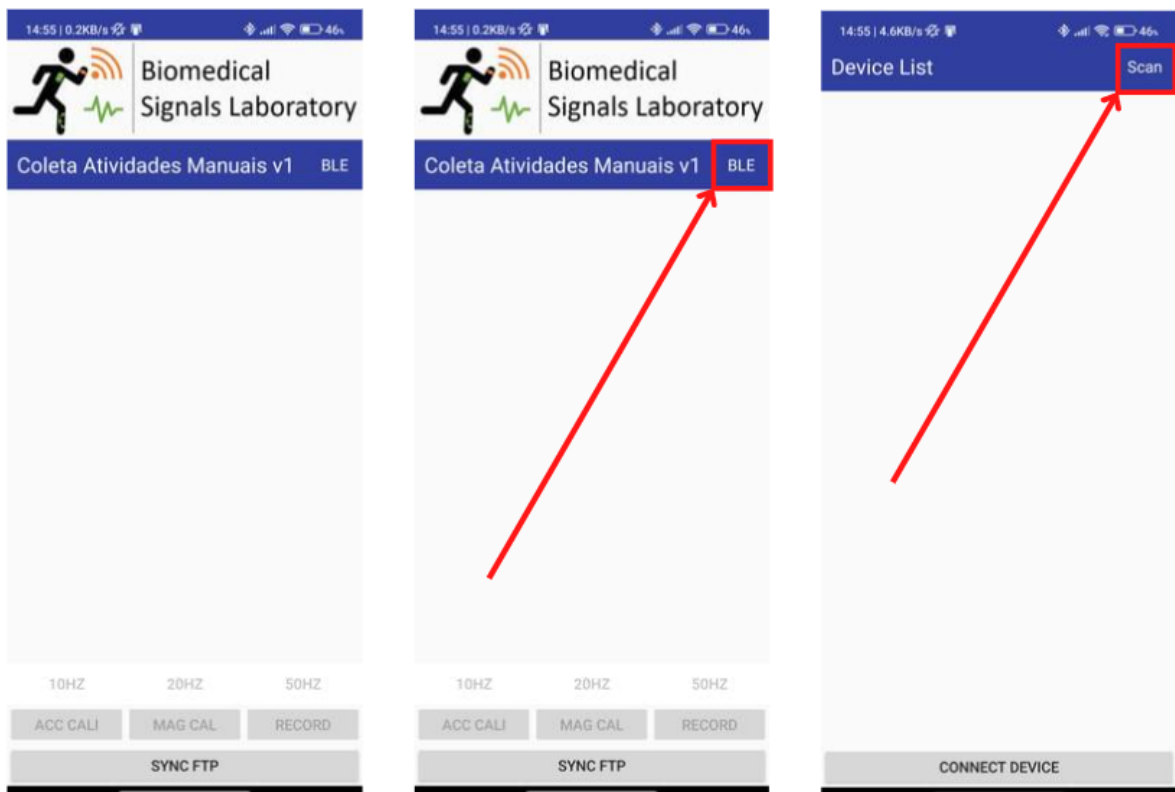
---

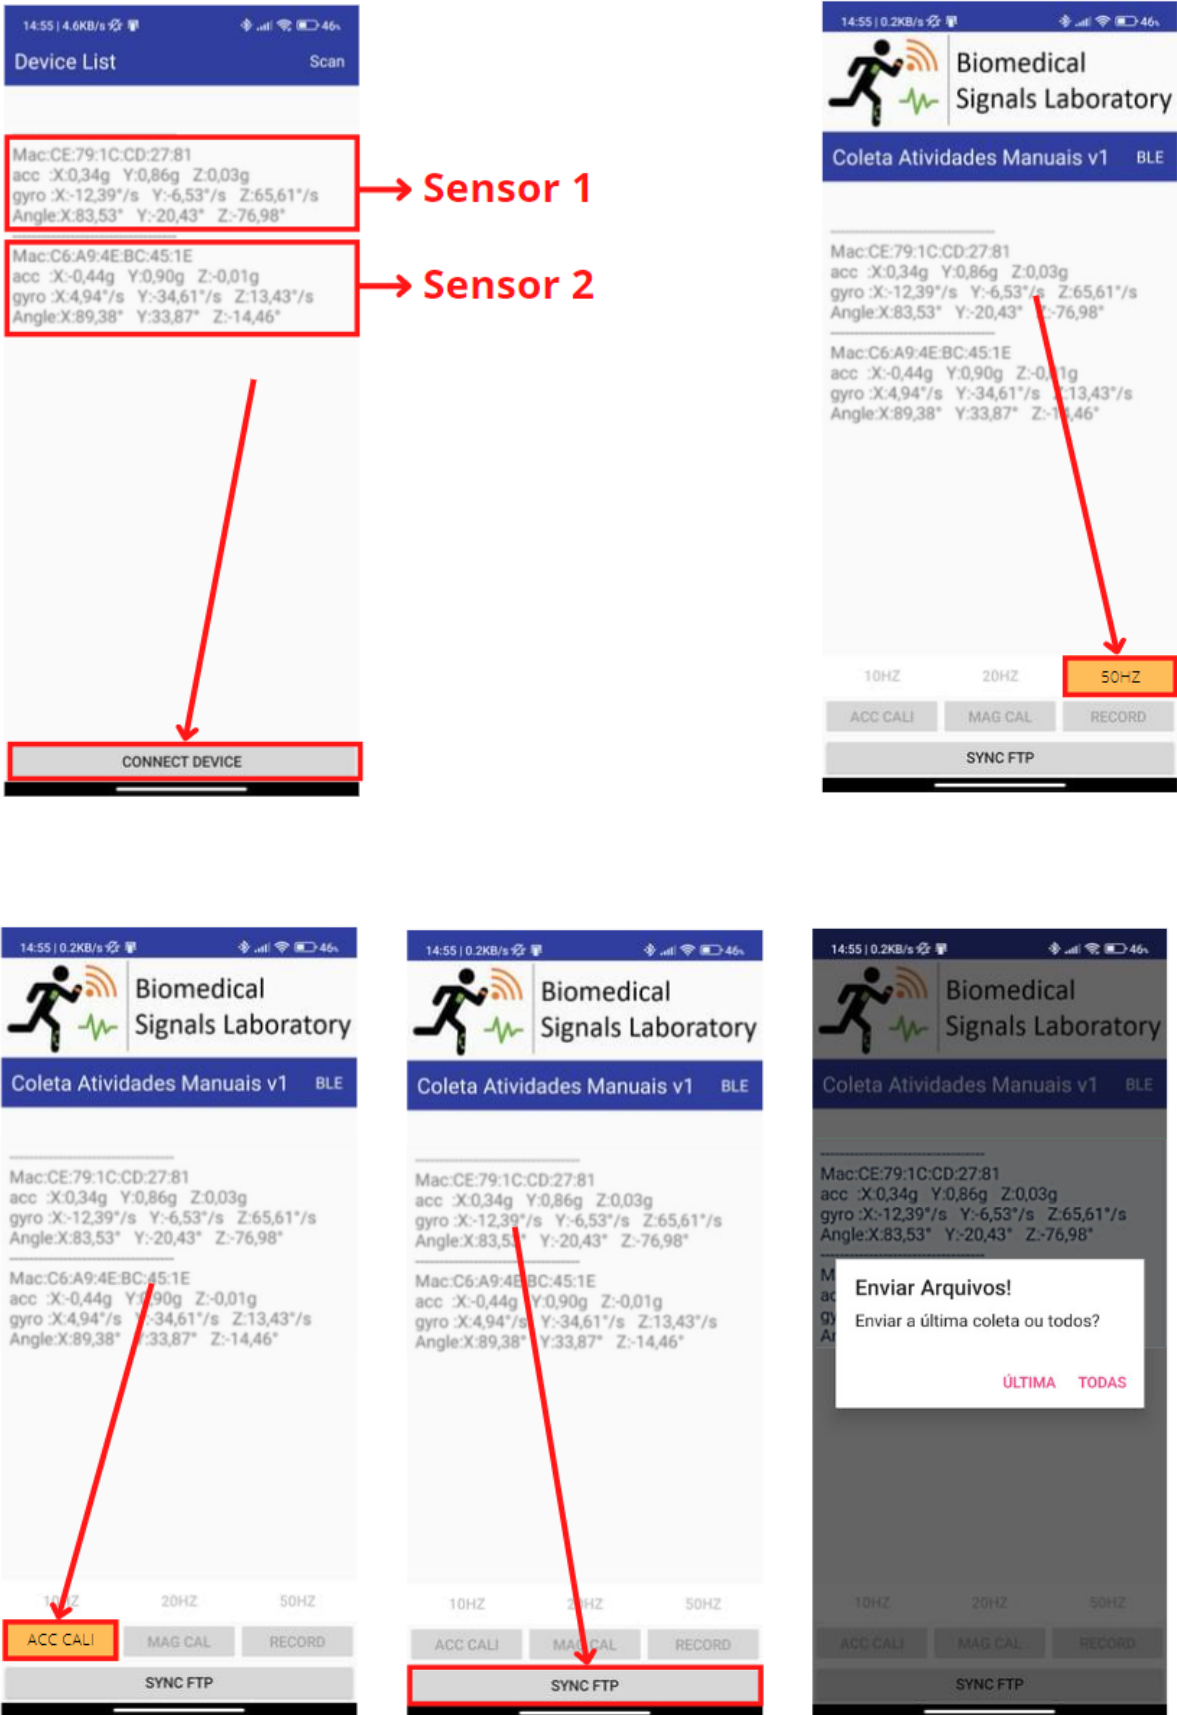
## APÊNDICE D

### Aplicativo e servidor FTP

---

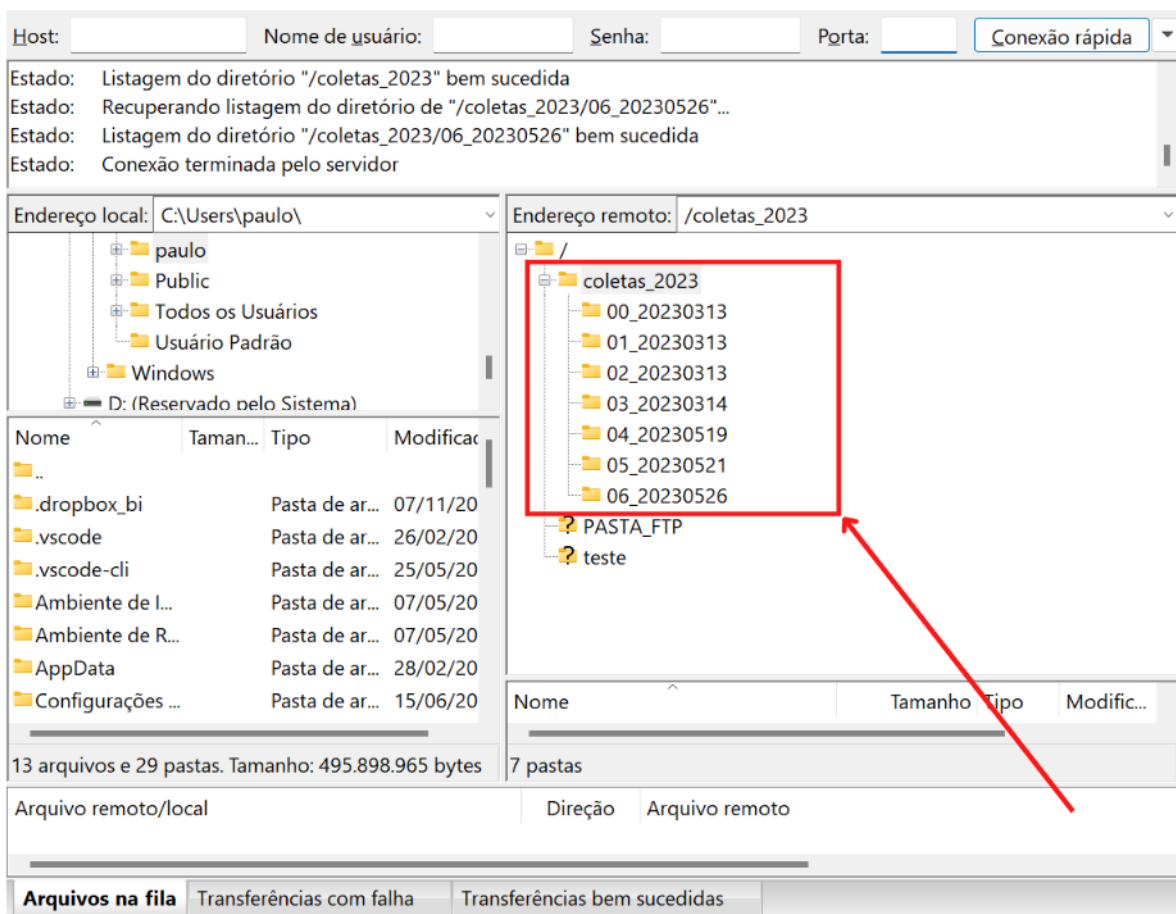
Figura 26 – Sequência para configuração do aplicativo





Fonte: Autor.

Figura 27 – Servidor em nuvem com os arquivos das coletas enviados pelo aplicativo.



Fonte: Autor.