



PROJETO FINAL DE GRADUAÇÃO

**Desenvolvimento de uma  
Bengala Enativa Afetiva para  
análise e prevenção de quedas:  
avanços em tecnologia assistiva**

**Diego Martins de Oliveira**

Graduação em Engenharia de Redes de Comunicação

Departamento de Engenharia Elétrica  
Faculdade de Tecnologia



**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE TECNOLOGIA**

**PROJETO FINAL DE GRADUAÇÃO**

**Desenvolvimento de uma  
Bengala Enativa Afetiva para  
análise e prevenção de quedas:  
avanços em tecnologia assistiva**

**Diego Martins de Oliveira**

*Projeto Final de Graduação submetido ao Departamento  
de Engenharia Elétrica como requisito parcial para o grau de  
Bacharelado em Engenharia de Redes de Comunicação*

**Banca Examinadora**

Dr. Adson Ferreira da Rocha, ENE/UnB  
*Orientador*

\_\_\_\_\_

Dra. Flávia Maria Guerra S. A. Oliveira, ENE/UnB  
*Examinadora Interna*

\_\_\_\_\_

Dra. Suélia de Siqueira Rodrigues Fleury Rosa,  
FGA/UnB  
*Examinadora Interna*

\_\_\_\_\_

## FICHA CATALOGRÁFICA

OLIVEIRA, DIEGO MARTINS

Desenvolvimento de uma Bengala Enativa Afetiva para análise e prevenção de quedas: avanços em tecnologia assistiva [Distrito Federal] 2023.

37 p., 210 x 297 mm (ENE/FT/UnB, Bacharelado, Engenharia de Redes de Comunicação, 2023).

Projeto Final de Graduação - Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Elétrica

1. Bengala Enativa Afetiva

2. Instrumentação

3. Aprendizado de Máquina

4. Idosos

I. ENE/FT/UnB

II. Title (series)

## REFERÊNCIA BIBLIOGRÁFICA

OLIVEIRA, D.M. (2023). *Desenvolvimento de uma Bengala Enativa Afetiva para análise e prevenção de quedas: avanços em tecnologia assistiva*. Projeto Final de Graduação, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 37 p.

## SESSÃO DE DIREITOS

AUTOR: Diego Martins de Oliveira

TÍTULO: Desenvolvimento de uma Bengala Enativa Afetiva para análise e prevenção de quedas: avanços em tecnologia assistiva.

GRAU: Bacharelado em Engenharia de Redes de Comunicação

ANO: 2023

É concedida permissão à Universidade de Brasília para reproduzir cópias deste Projeto Final de Graduação e para emprestar ou vender tais cópias apenas para fins acadêmicos e científicos. Da mesma forma, a Universidade de Brasília está autorizada a publicar este documento em uma biblioteca virtual, em formato que permita o acesso por meio de redes de comunicação e a reprodução de cópias, desde que protegida a integridade do conteúdo dessas cópias e proibido o acesso a partes isoladas desse conteúdo. Os autores reservam outros direitos de publicação e nenhuma parte deste documento pode ser reproduzida sem permissão por escrito do autor.

---

Diego Martins de Oliveira  
Departamento de Engenharia Elétrica (ENE) - FT  
Universidade de Brasília (UnB)  
Campus Darcy Ribeiro  
CEP: 70919-970 - Brasília-DF - Brasil

---

## RESUMO

Os conceitos dos sistemas enativos afetivos investigam a interação entre seres humanos, tecnologias e ambiente, com o objetivo de aprimorar a mobilidade e a saúde por meio da cognição incorporada, compreendendo como o ser humano afeta e é afetado pelo mundo. Hoje, o Brasil tem uma das maiores populações idosas do mundo e o processo de envelhecimento causa diminuição da capacidade de caminhar, o que pode aumentar o risco de quedas. O uso de um dispositivo auxiliar de marcha visa proporcionar maior segurança e autonomia para a população idosa, reduzindo a ocorrência de quedas e, por isso, foi escolhida uma bengala como objeto para desenvolvimento deste projeto. Utilizar dados deste sistema para aumentar a percepção do usuário e gerar a chamada cognição incorporada, confere a qualidade de sistema enativo afetivo, transformando este objeto na Bengala Enativa Afetiva.

Neste trabalho multidisciplinar são apresentados o desenvolvimento de dois protótipos da bengala enativa afetiva. Bengalas comuns, de alumínio e ajustáveis, foram instrumentadas com microcontroladores e diferentes sensores. Além disso, foram discutidas diferentes formas de captura e armazenamento dos dados para processamento. Alguns testes foram propostos para avaliar risco de queda de idosos e testes pilotos do tipo Timed Up and Go foram executados com três voluntários hígidos. Seis algoritmos de aprendizado de máquina foram comparados em termos de performance na classificação de padrões de marcha.

As análises dos modelos de aprendizado de máquina para detecção de caminhada rápida e lenta revelaram resultados distintos. A regressão logística falhou ao classificar corretamente ambas as atividades, enquanto o vetor de suporte teve dificuldades na identificação da caminhada rápida. A floresta randômica obteve desempenho moderado, e o vizinho mais próximo foi o segundo melhor em desempenho geral. O Naive Bayes apresentou limitações na detecção da caminhada rápida, com resultados insatisfatórios. A árvore de decisão destacou-se como o melhor algoritmo.

**Palavras-chave: Bengala Enativa Afetiva, Instrumentação, Aprendizado de Máquina, Idosos**

---

## ABSTRACT

The concepts of affective enactive systems investigate the interaction between human beings, technology, and the environment, aiming to enhance mobility and health through embodied cognition, understanding how humans affect and are affected by the world. Today, Brazil has one of the largest elderly populations in the world, and the aging process leads to a decrease in walking capacity, which can increase the risk of falls. The use of an assistive walking device aims to provide greater safety and autonomy for the elderly population, reducing the occurrence of falls. Therefore, a cane was chosen as the object for the development of this project. Using data from this system to enhance user perception and generate what is known as embodied cognition bestows the quality of an affective enactive system, transforming this object into the Affective Enactive Cane.

In this multidisciplinary work, the development of two prototypes of the affective enactive cane is presented. Common aluminum adjustable canes were instrumented with microcontrollers and various sensors. In addition, different methods of data capture and storage for processing were discussed. Several tests were proposed to assess the risk of falls in the elderly, and pilot Timed Up and Go tests were conducted with three healthy volunteers. Six machine learning algorithms were compared in terms of their performance in classifying gait patterns.

The analyses of the machine learning models for detecting fast and slow walking revealed distinct results. Logistic regression failed to correctly classify both activities, while the support vector machine had difficulty identifying fast walking. Random forest achieved moderate performance, and k-nearest neighbors ranked second in overall performance. Naive Bayes showed limitations in detecting fast walking, with unsatisfactory results. Decision tree emerged as the best-performing algorithm.

**Key-words: Affective Enactive Cane, Instrumentation, Machine Learning, Elderly**

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>2</b>	<b>OBJETIVOS</b>	<b>2</b>
2.1	OBJETIVO GERAL	2
2.2	OBJETIVOS ESPECÍFICOS	2
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>3</b>
3.1	DISPOSITIVO AUXILIAR DE MARCHA	3
3.2	AVALIAÇÃO DO RISCO DE QUEDA	4
3.3	SISTEMAS ENATIVOS AFETIVOS	4
3.4	APRENDIZADO DE MÁQUINA (MACHINE LEARNING)	7
3.4.1	TIPOS DE APRENDIZADO NO APRENDIZADO DE MÁQUINA	8
<b>4</b>	<b>METODOLOGIA</b>	<b>12</b>
4.1	<i>Background</i> EM ANATOMIA E ESTUDO DE SINAIS FISIOLÓGICOS	12
4.2	VERSÃO PRELIMINAR DA BENGALA	13
4.3	SEGUNDA VERSÃO DA BENGALA	21
4.4	EXPERIMENTOS DE AVALIAÇÃO DA BENGALA: ESTUDO PILOTO	24
<b>5</b>	<b>RESULTADOS</b>	<b>29</b>
<b>6</b>	<b>CONCLUSÃO</b>	<b>33</b>
<b>7</b>	<b>REFERÊNCIAS</b>	<b>35</b>

## LISTA DE FIGURAS

3.1	Tipos de Aprendizado de Máquina (Jiang, 2023).....	8
3.2	Fluxo de trabalho do aprendizado supervisionado (Mahesh, 2020).....	9
3.3	Fluxograma Árvore de decisão (Mahesh, 2020).....	9
3.4	Esquema Support Vector Machine (Mahesh, 2020).....	10
3.5	Esquema Floresta Randômica (Pant et al., 2022).....	10
3.6	Simple exemplo de KNN (Taunk et al., 2019).....	11
4.1	Esboço conceitual da versão preliminar da bengala enativa afetiva (Autor).....	13
4.2	MPU-6050 (Hassan, 2019).....	14
4.3	Orientação e polaridade de rotação do MPU-6050 (Hassan, 2019).....	14
4.4	Sensor HRCSR04 (Autor).....	15
4.5	Sensor DHT11 à esquerda e sensor FSR à direita (Autor).....	15
4.6	Sensor LDR (Xcluma).....	16
4.7	Sensor GSR V1.2 (Autor).....	16
4.8	<i>Pulse Sensor</i> (Autor).....	17
4.9	Exemplo de bateria de 9 volts e chave switch (Autor).....	17
4.10	Arduino Uno à direita e o módulo <i>bluetooth</i> HC-05 à direita (Autor).....	18
4.11	Exemplo de código no Arduino IDE (Autor).....	18
4.12	Placa de circuito impresso desenvolvida à esquerda e exemplo de esquemático de placa de circuito impresso à direita (Autor).....	19
4.13	Arduino com PCI na carenagem aberta à esquerda e pegador da bengala com <i>Pulse Sensor</i> e botão na bengala incorporados (Autor).....	19
4.14	Fluxograma sobre taxa de amostragem do <i>firmware</i> para captura dos dados dos sensores de versão da bengala (Autor).....	20
4.15	Programa de computador criado para visualização dos testes e armazenamento dos dados à esquerda e o autor realizando um teste à direita (Autor).....	20
4.16	Monitor cardíaco Polar (Polar).....	21
4.17	Protótipo da Bengala Enativa Afetiva (Autor).....	22
4.18	Visão interna do dispositivo (Autor).....	23
4.19	Interface externa do dispositivo (Autor).....	24
4.20	Esquemático de placa de circuito impresso criado para a nova versão da bengala (Autor).....	24
4.21	Trajeto dos testes realizados (Autor).....	26
4.22	Exemplo de log capturado.....	27
5.1	Gráfico de resultados do TUG.....	29

## LISTA DE TABELAS

4.1	Classificação de velocidades dos testes .....	26
5.1	Índices obtidos de cada algoritmo .....	30
5.2	Matrizes de confusão .....	31

## Lista de Abreviaturas

ANN	Rede Neural Artificial
DAM	Dispositivo Auxiliar de Marcha
DMP	Processador de Movimento Digital
HCI	Interação Humano-Computador
HRV	Variabilidade da frequência cardíaca
IA	Inteligência Artificial
IDE	Integrated Development Environment
KNN	K Vizinhos próximos
MEMS	Sistemas Micro-Eletromecânicos
ML	Aprendizado de Máquina
NB	<i>Naive Bayes</i>
SOC	System on Chip
SVM	<i>Support Vector Machine</i>
TUG	<i>Timed Up and Go</i>

# 1 INTRODUÇÃO

O Brasil possui uma das maiores populações idosas em todo o mundo, com aproximadamente um quarto da população (54 milhões de pessoas) tendo 50 anos de idade ou mais, e cerca de 30 milhões de brasileiros com 60 anos ou mais (Lima-Costa et al., 2023). De acordo com Song et al. (2018), o processo de envelhecimento pode levar a uma redução na capacidade de locomoção, o que aumenta o risco de quedas. Pimentel et al. (2018) relatam que a prevalência de quedas na população idosa residente em áreas urbanas no Brasil foi de 25,1%, conforme constatado em uma pesquisa realizada entre 2015 e 2016.

Este projeto multidisciplinar tem como objetivo o desenvolvimento de um sistema enativo afetivo inovador, focado na avaliação do risco de quedas em idosos. Considerando que dispositivos auxiliares de marcha são frequentemente recomendados para alguns idosos com dificuldades de locomoção, a bengala foi selecionada como o objeto central para o desenvolvimento desse sistema enativo afetivo.

Ao equipar a bengala com sensores, é possível capturar e processar sinais relevantes para o usuário. Esses sensores permitem a obtenção de informações precisas e valiosas sobre a marcha e movimentação do idoso, criando assim uma espécie de "mapa vivo" que reflete as narrativas e experiências do usuário durante o uso da bengala.

Por meio da análise desses dados, busca-se aprimorar a percepção do usuário em relação à bengala e entender como ele é afetado e, por sua vez, como afeta o seu ecossistema. Essa abordagem, conhecida como "cognição incorporada", confere ao sistema a qualidade de ser enativo e afetivo, pois a tecnologia interage de forma mais empática e intuitiva com o usuário, tornando a bengala uma verdadeira "Bengala Enativa Afetiva". Com essa inovação, espera-se proporcionar maior segurança e bem-estar aos idosos, reduzindo os riscos de quedas e promovendo uma abordagem mais holística para a assistência à saúde dessa população.

Neste trabalho é relatado o desenvolvimento técnico de duas versões da bengala, a realização de testes para avaliação do risco de queda e a comparação de diferentes algoritmos de aprendizado de máquina para classificação de padrões de marcha. A equipe foi coordenada pelos orientadores Adson Ferreira da Rocha, que coordenou a parte técnica, e Diana Maria Gallicchio Domingues, idealizadora do projeto e autoridade internacional em Sistemas Enativos Afetivos. O autor foi responsável pelo desenvolvimento do Hardware e Software da Bengala Enativa Afetiva, junto ao bolsista Pedro de Oliveira Moura e Souza e o engenheiro Pedro Henrique Gonçalves Inazawa, que também liderou o desenvolvimento dos algoritmos dos classificadores utilizados no projeto. A fisioterapeuta Amabylli Mikaele Costa Luz liderou a etapa de testes de avaliação de risco de queda realizados. Como as discussões e desenvolvimento do projeto são transversais, obtendo resultados integrados, abaixo estão descritas as etapas de desenvolvimento do projeto e as discussões do mesmo, bem como os resultados obtidos e expectativas de trabalhos futuros.

## **2 OBJETIVOS**

### **2.1 OBJETIVO GERAL**

O objetivo deste projeto é desenvolver uma bengala equipada com as características de um sistema enativo afetivo, e posteriormente, avaliar a sua utilização como meio de análise para identificar e avaliar o risco de quedas em usuários.

### **2.2 OBJETIVOS ESPECÍFICOS**

- Desenvolver uma bengala instrumentada capaz de capturar sinais locativos, ambientais e fisiológicos, garantindo variabilidade de informações, robustez dos dados obtidos e máxima autonomia na captura destes.
- Examinar a efetividade do aparelho para detectar medidas relacionadas à avaliação de risco de queda.
- Propor e comparar diferentes algoritmos de aprendizado de máquina para classificação de padrões de marcha, a fim de calcular o grau de risco de queda.

# 3 FUNDAMENTAÇÃO TEÓRICA

## 3.1 DISPOSITIVO AUXILIAR DE MARCHA

A marcha possibilita a autonomia das pessoas, permitindo-lhes fugir do perigo, buscar suas necessidades básicas, trabalhar e interagir com os outros. Contudo, essa habilidade pode ser limitada ou comprometida em deficientes, pessoas com mobilidade reduzida e idosos. A indicação preventiva do uso de um dispositivo auxiliar de marcha (DAM) adequado é uma estratégia que visa proporcionar maior segurança e autonomia para a população idosa, além de reduzir a ocorrência de quedas. (KAPANDJI, 2011).

Os DAMs são classificados em três grandes grupos: bengalas, muletas e andadores. Eles são prescritos por diversas razões, incluindo problemas clínicos como dor, sobrecarga estrutural, déficit de equilíbrio, instabilidade articular e fadiga. Além disso, esses dispositivos podem eliminar a descarga total ou parcial sobre um membro inferior, transferindo a força dos membros superiores para o chão através da pressão sobre o dispositivo de assistência (O'SULLIVAN et al., 2018).

A bengala tem como objetivos aumentar a base de apoio, reduzir a carga nos membros inferiores (no máximo 20% do peso corporal), fornecer informações sensoriais adicionais e auxiliar na aceleração e desaceleração durante a marcha. Suas funções prescritivas incluem diminuir a dor, compensar o déficit de força, melhorar o equilíbrio, diminuir a dor, proteger o membro prejudicado e facilitar o deslocamento pelo ambiente. Geralmente, é utilizada com apenas uma mão (SAAD, 2007). Evidências sugerem a eficácia desse tipo de DAM na melhora do equilíbrio e estabilidade postural (O'SULLIVAN et al., 2018).

De acordo com O'Sullivan et al. (2018), tem-se vários tipos de bengala: a convencional de madeira ou acrílico, com pegador semicírculo ou em forma de T, a qual não é ajustável em altura. A convencional ajustável de alumínio possui o mesmo design, mas sua altura é ajustável. A curva ajustável de alumínio tem o componente proximal da haste deslocado anteriormente e tem altura ajustável. Outro tipo é a bengala de quatro pontos, feita de alumínio, que oferece uma base ampla com quatro pontos de contato com o solo, porém pode gerar instabilidade. A hemicane, também em alumínio, tem base alargada com quatro pontos de apoio no solo, é dobrável e possui altura ajustável, mas também pode apresentar problemas de instabilidade. Por fim, a bengala a laser projeta uma linha vermelha no chão para ajudar em episódios de congelamento durante a deambulação.

Usualmente, a altura do trocanter maior corresponde à altura de uma bengala, enquanto o cotovelo deve estar fletido de 20° a 30°. É importante destacar que o grau de flexão do cotovelo é o indicador mais relevante, pois variações no comprimento do corpo e dos membros podem ocorrer. Esse grau de flexão tem funções fundamentais, permitindo que o braço se mova durante as fases da marcha e também atuando na absorção do impacto (O'SULLIVAN et al., 2018).

A fim de garantir um adequado uso da bengala são estabelecidas algumas recomendações (O'SULLIVAN et al., 2018):

- Segurar a bengala com a mão oposta ao membro afetado, de modo a se aproximar de um padrão de

marcha normal, onde braço e perna opostos se movem em sincronia.

- É essencial manter a bengala próxima ao corpo.
- Em superfícies regulares, tanto a bengala quanto o membro afetado avançam simultaneamente.

Quando há comprometimento bilateral, a escolha do lado em que a bengala será utilizada deve levar em conta fatores como o conforto e a segurança do indivíduo, além de considerar melhorias no equilíbrio, padrão de marcha e força de preensão entre as mãos

### **3.2 AVALIAÇÃO DO RISCO DE QUEDA**

Segundo Alencar et al. (2017), os testes mais utilizados para estimar o risco de queda em idosos são o *Teste Up and Go* (TUG) (PODSILADLO et al., 1991), a Escala de Equilíbrio de Berg (BERG et al., 1992) e a Escala de Equilíbrio e Marcha de Tinetti (TINETTI et al., 1990).

O TUG destaca-se entre outros testes devido à sua ampla aplicabilidade no contexto clínico e científico, sendo facilmente compreendido, de baixo custo e com alta confiabilidade. É um teste que permite avaliar o equilíbrio e a mobilidade funcional por meio de uma atividade dinâmica, o que o torna conveniente, rápido e requer apenas alguns equipamentos (KARUKA et al., 2011). Além disso, o resultado do TUG está diretamente relacionado com a propensão a quedas: quanto maior o tempo obtido no teste, maior é a probabilidade de ocorrer uma queda (SAAD et al., 2007).

O TUG é um teste aplicado globalmente e recomendado pela *American and British Geriatrics Societies* para avaliação de risco de quedas (GREENE et al., 2010). Consiste em um conjunto de atividades fundamentais para mobilidade independente e foi escolhido como base para este trabalho.

O desempenho do teste está relacionado com o tempo de reação, a força muscular dos membros inferiores (MMII) e a habilidade da marcha, avaliando o equilíbrio sentado e em pé, assim como a estabilidade e o desempenho para mudança de direção durante a marcha. O teste consiste em registrar o tempo gasto em segundos que o indivíduo leva para se levantar de um assento padrão, caminhar em uma linha no chão com 3 metros de comprimento, virar, voltar e sentar-se novamente, com a pontuação correspondendo ao tempo gasto (PODSILADLO et al., 1991). Existem algumas estratificações em relação ao risco de queda, onde Wall et al. (2000) propõem a seguinte escala: risco baixo de queda (< 10 segundos), risco moderado (10–20 segundos) e risco elevado (> 20 segundos).

### **3.3 SISTEMAS ENATIVOS AFETIVOS**

De acordo com Domingues (2019), a teoria enativa de cognição incorporada é uma abordagem que se originou das ideias inovadoras de Humberto Maturana e Francisco Varela, ao explorarem a interação entre Biologia e Cognição. Essa teoria tem sido uma fonte significativa de inspiração tanto no campo científico quanto filosófico. Ela valida uma compreensão fundamental da vida e da cognição como processos e experiências que estão intimamente ligados ao corpo, refletindo sua constituição biológica, histórico pessoal e

contexto cultural. Em outras palavras, os processos mentais e o conhecimento são moldados pela biologia, nossa história de vida e o ambiente cultural em que estamos inseridos. Essa perspectiva desafia as visões tradicionais que enfatizam a mente como um sistema isolado e enfatiza a importância das interações do organismo com o ecossistema para o entendimento da cognição e da experiência humana. A perspectiva pré-dada do mundo é substituída por uma visão de um mundo vivo e interconectado quando se trata de sistemas enativos.

No conceito de "cognição incorporada", o conhecimento não é apenas descoberto, mas ativamente construído pelas pessoas através de suas experiências vividas e interações com o mundo. Isso valoriza a experiência e o contexto na construção do conhecimento, abrindo novas possibilidades para a arte, ciência e filosofia. Pesquisas recentes sobre Sistemas Enativos Afetivos exploram mudanças na vida humana, especialmente em questões comportamentais relacionadas à interação entre as pessoas, o ambiente e as tecnologias. Nesse contexto, o corpo é visto como algo moldado pela sociedade, e os protótipos ampliam a relação entre o corpo, experiências vividas e dados. Isso se aplica a áreas como saúde, reabilitação, educação e medicina, abrangendo pesquisas em ciência cognitiva que se concentram na ampliação ou suplementação da percepção.(Domingues, 2019).

Nos sistemas enativos afetivos, as ações humanas criam representações dinâmicas, como mapas vivos utilizando elementos como respiração, calor, batimentos cardíacos, dados climáticos, poluição e voz , que representam nossas experiências e histórias pessoais, geografias afetivas, que se referem às nossas emoções e como elas estão relacionadas à nossa experiência no espaço e no ambiente em que vivemos, e narrativas de organismos, que são as histórias individuais que construímos a partir de nossas experiências e ações, influenciadas pelo ambiente ao nosso redor. Essa perspectiva revela uma forma de entender a realidade e sua essência existencial, relacionada intimamente à nossa conexão com o ambiente. Isso nos permite perceber que nossas ações e experiências vividas são uma maneira de "cognição incorporada"(Domingues, 2019).

Varela (1999) destaca que todos os processos cognitivos são emocionais-afetivos e que o afeto é uma dinâmica pré-verbal e pré-reflexiva na formação do ser. Domingues ressalta que sistemas enativos afetivos estabelecem um diálogo significativo com o ambiente, envolvendo organismos afetados por tecnologias que enviam sinais e geram narrativas afetivas por meio de representações vivas em visualizações de dados relacionados à fisiologia dos seres.

Domingues salienta que a cultura é enriquecida pelos sistemas enativos, ampliando as relações entre o ser humano e o ambiente por meio de tecnologias que facilitam as interações sócio-afetivas. Essa abordagem valoriza a conexão contínua entre as pessoas e seu ambiente, e utiliza o aparato tecnológico como ferramenta para enriquecer a experiência humana e suas relações com o mundo ao redor.

A intersecção de conceitos dos sistemas enativos transcende diversas disciplinas e inspira colaborações de "Novos Leonardos", que unem saberes multidisciplinares para uma criação, buscando abordar preocupações e objetos compartilhados, visando resultados integradores. Isso torna diferentes ciências e disciplinas parte de uma ciência unificada, o que justifica a incorporação dessa pesquisa no domínio da *eSciences*, onde todos os projetos contam com uma base computacional ativa para alcançar os resultados desejados. Essa abordagem interdisciplinar e tecnologicamente avançada promove uma visão holística para compreender e solucionar questões complexas, proporcionando inovações significativas (Domingues, 2023, não

publicado).

As tecnologias enativas são incorporadas no campo da Interação Humano-Computador (HCI), mas vão além do uso tradicional de dispositivos tecnológicos com a simples interação mediada por computador através de imagens e símbolos. Elas englobam um conhecimento enativo de experienciar ambientes, onde o saber é fundamentado na participação ativa e no conhecimento adquirido por meio da vivência e da experiência direta, permitindo uma compreensão mais profunda e significativa do mundo, considerando a vivência como fonte de conhecimento valioso (Domingues, 2019).

As tecnologias naturalizadas e seus protótipos exploram dispositivos que possuem capacidades sensoriais, podendo perceber e responder a estímulos do ambiente ao seu redor, capazes de se mesclar e se adaptar ao ambiente, contribuindo para a visualização e processamento de sinais. Essas pesquisas buscam um "novo abstracionismo", que envolve compreender e representar visualmente o invisível, como os fenômenos da vida, a experiência humana e seus afetos. Esse campo promissor é um território fértil para a investigação científica e inovação disruptiva na reengenharia da vida. Os protótipos gerados em tecnologias criativas para a saúde podem ser considerados inovação disruptiva, pois revisitam e reconfiguram dispositivos com inventos anteriores, mas se abrem e permitem outras formas de agir no cotidiano (Domingues, 2019).

No campo da *Mhealth*, ou *mobile health*, o uso de dispositivos móveis e sensores permitem criar narrativas afetivas, que são uma forma de mineração da realidade, ou seja, de coletar informações da vida cotidiana (Pentland et al., 2009). Isso significa que as ações das pessoas são transformadas em dados que podem ser apresentados visualmente, ouvidos ou expressos de maneiras criativas para contar histórias sobre suas vidas.

Essa pesquisa transdisciplinar coloca os Sistemas Enativos Afetivos além das telas, ou seja, eles interagem ativamente com o ambiente, coletando dados do sujeito usuário do sistema e do ecossistema, através de sensores que monitoram aspectos fisiológicos, ambientais e de localização. A partir dessas informações, surgem narrativas enativas afetivas, ao medir as variações nos modos de sentir dos organismos e as trocas afetivas (afetos) durante a experiência com o ambiente. Esses sistemas enativos estendem-se para diálogos e interações com o mundo físico, como no ato de caminhar, já que captam e modelam a percepção do mundo, obtendo dados que carregam consigo informações interessantes para estudos.

O objetivo é desenvolver sistemas enativos afetivos, combinando hardware e software, que transformem a interação humana com o ambiente, permitindo maior mobilidade e liberdade de locomoção, utilizando do conceito dos "Novos Leonardos", que reúnem conhecimentos de diversas áreas, contribuem para que a Arte seja um espaço íntimo de experiências afetivas na reengenharia da vida.

Os sistemas enativos afetivos são dotados de capacidade de reconhecimento e entrelaçamento dos organismos com os ambientes. Os sensores que compõem sistema traçam os mapas vivos a partir das trocas mútuas entre dados, ambiente e os organismos, chamados de narrativas enativas afetivas, chegando numa cognição incorporada, incluindo sinais fisiológicos e características dos organismos vivos nesta relação. O mundo objetivo dá lugar a um mundo construído através da corporeidade e das interações, dependendo da experiência vivida e das percepções do sujeito. Os Sistemas Enativos Afetivos são capazes de compreender como o ser afeta o ambiente que vive e como é afetado por este.

### 3.4 APRENDIZADO DE MÁQUINA (MACHINE LEARNING)

Atualmente, existem novas tecnologias que podem utilizar informações já existentes para identificar padrões conhecidos com base em experiências anteriores. Uma dessas abordagens é o Aprendizado de Máquina, também conhecido pela sigla em inglês, *Machine Learning* (ML). O Aprendizado de Máquina refere-se a técnicas computacionais que permitem que um programa de computador "aprenda" a identificar padrões por meio de treinamento ou experiência, sem a necessidade de utilizar extensos métodos de programação. Essas técnicas fazem parte de um campo mais amplo chamado "inteligência artificial". (ALPAYDIN, 2010, Mahesh, 2020).

O campo do Aprendizado de Máquina surgiu com a definição pioneira de Arthur Samuel (1959) que descreveu ML como uma área de estudo que concede aos computadores a habilidade de aprender sem necessidade de programação explícita. Outra abordagem para definir Aprendizado de Máquina (ML), apresentada pela IBM Education em 2020, o descreve como um ramo da Inteligência Artificial (IA) e da ciência da computação. Seu foco principal é utilizar dados e algoritmos para simular a maneira como os seres humanos aprendem, permitindo que a precisão do sistema melhore gradualmente ao longo do tempo. O ML está estreitamente vinculado à Inteligência Artificial (IA). Conforme apontado por Russell et al. (2010), a IA é uma ferramenta computacional com a capacidade de executar ações ou fornecer respostas similares às ações humanas. Essa área de estudo está integrada em diferentes campos do conhecimento, abrangendo uma ampla gama de aplicações e possibilidades, como por exemplo a matemática, a engenharia, a linguística, a neurociência, a economia e a filosofia.

A história da Inteligência Artificial (IA) se iniciou a aproximadamente 80 anos, quando teve sua primeira aplicação em 1943. Warren McCulloch e Walter Pitts foram pioneiros nesse campo, criando um dos primeiros modelos de neurônios artificiais com estados "ligado/desligado". Eles simularam a resposta desses neurônios a um estímulo psicológico (Russell et al., 2010). A descoberta de McCulloch e Pitts foi reveladora, mostrando que a combinação desses neurônios em uma rede poderia aumentar significativamente a capacidade de computação. A partir desse marco, novas metodologias surgiram para aplicar a IA, resultando em aprimoramentos das ferramentas de programação. Como consequência desse progresso, a IA evoluiu para se tornar uma poderosa e versátil ferramenta, capaz de resolver problemas complexos e tomar decisões em diversas áreas, como medicina, tecnologia, engenharia, marketing, psicologia e outras.

A utilização da Aprendizagem de Máquina (ML) ou Inteligência Artificial (IA) para diversas análises tem se expandido consideravelmente, devido à sua facilidade de aplicação, permitindo o uso de algoritmos específicos sem a necessidade de códigos extensos e complicados. Segundo Géron (2019), as vantagens do ML são notáveis:

- Mediante um código ou algoritmo mais simples, é possível solucionar problemas que antes exigiam grande esforço humano ou uma infinidade de regras condicionais.
- ML busca técnicas eficientes para resolver problemas complexos que não encontram solução por meio dos métodos tradicionais.
- A capacidade de adaptação às informações existentes, incluindo aquelas adquiridas recentemente, confere maior agilidade e eficácia ao sistema.

- Com ML, é possível obter resultados significativos a partir de uma vasta quantidade de dados, proporcionando *insights* valiosos e relevantes.

### 3.4.1 Tipos de aprendizado no aprendizado de máquina

A Aprendizagem de Máquina (Machine Learning - ML) está embasada na utilização das informações disponíveis para encontrar resoluções para questões particulares. Tal como mencionado anteriormente, cada questão exibe características únicas, tornando essencial a identificação do algoritmo mais apropriado para atingir a solução desejada. Dentro dessa perspectiva, a ML pode ser amplamente classificada em três modalidades de análise, cada uma concentrada em um princípio de aprendizagem específico: Aprendizado Supervisionado, Aprendizado Não Supervisionado e Aprendizado Reforçado (Abraham, 2005; Shahin et al., 2008).

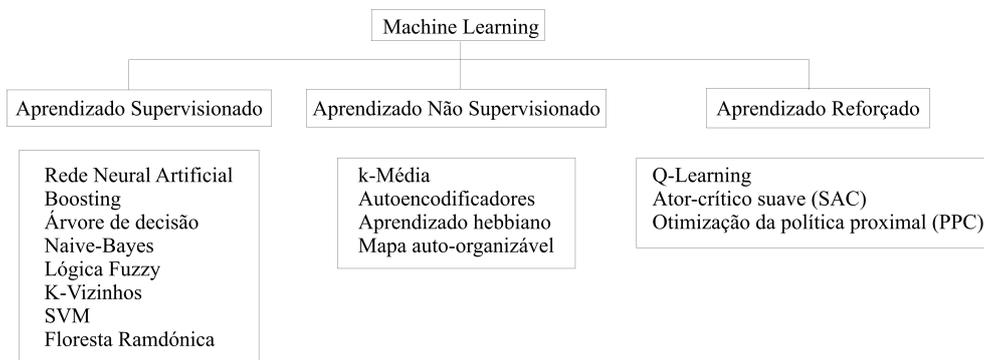


Figura 3.1: Tipos de Aprendizado de Máquina (Jiang, 2023)

#### 3.4.1.1 Aprendizado Supervisionado

Dentro do contexto do aprendizado supervisionado, tanto os dados de entrada quanto os dados de saída, também chamados de resposta desejada, são conhecidos, o que possibilita a avaliação precisa através da comparação de erros. Nessa modalidade de aprendizado, que é referida como aprendizado com um tutor (Haykin, 1999), o conhecimento é representado por uma entrada associada a um exemplo de saída correspondente. O aprendizado supervisionado pode ser subdividido em duas categorias distintas de tarefas. A primeira delas é a Classificação, na qual o algoritmo atua como um filtro para determinar a saída desejada. Enquanto isso, a segunda tarefa é a Previsão, em que um valor alvo é gerado a partir de um conjunto de dados de entrada, também conhecido como preditores, que são treinados por meio de exemplos (Géron, 2019). Além disso, a regressão estatística estabelece uma relação entre as variáveis independentes (preditores) e o resultado previsto.

Existem diversos algoritmos empregados no aprendizado supervisionado, e a seguir, serão fornecidas breves descrições de alguns dos mais frequentemente utilizados.

Segundo Maglogiannis (2007), a *Árvore de Decisão* é uma técnica amplamente empregada para classificar dados através de uma estrutura em formato de árvore. Cada nó desta árvore representa um caso de classificação da informação, e cada ramo representa um valor de saída que pode ser assumido. A raiz da

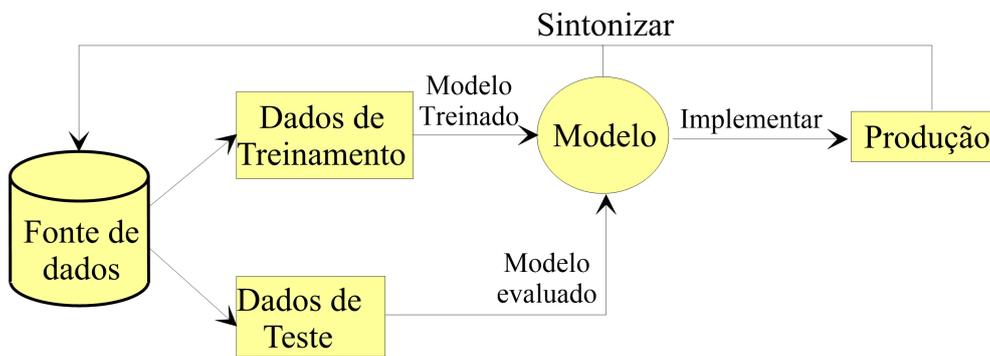


Figura 3.2: Fluxo de trabalho do aprendizado supervisionado (Mahesh, 2020)

árvore é definida com base no ramo que melhor separa os dados de treinamento. Durante o processo, o algoritmo realiza múltiplas divisões até encontrar subárvores com as mesmas classes no mesmo nível.

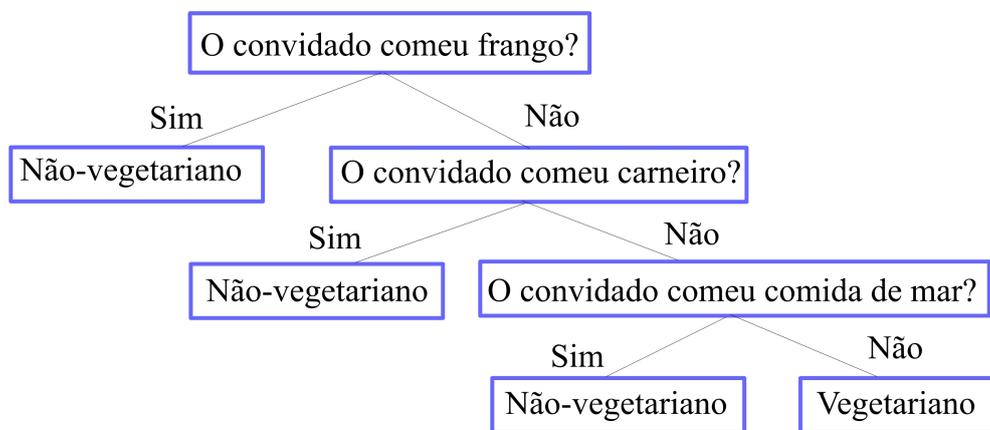


Figura 3.3: Fluxograma Árvore de decisão (Mahesh, 2020)

O algoritmo Naive Bayes, também conhecido como "NB", é uma técnica de classificação que utiliza a análise de probabilidades dos dados para realizar previsões. O termo *naive* (ingênuo) está relacionado à suposição de independência entre os preditores, ou seja, cada dado é tratado como se fosse independente dos outros. Essa abordagem se baseia no teorema de Bayes (Ray, 2019). O método Naive Bayes é altamente valorizado na indústria de classificação de texto, graças à sua eficácia na realização de tarefas de agrupamento (*clustering*) e classificação com base nas probabilidades condicionais de ocorrência (Mahesh, 2020).

O *Support Vector Machine* (SVM) é uma técnica de aprendizado de máquina amplamente utilizada para classificação e análise de regressão. Além de classificação linear, os SVMs também podem lidar com classificação não linear usando o "truque do kernel", o que os torna versáteis em problemas complexos. Eles definem margens entre as classes para maximizar a distância e reduzir o erro de classificação (Mahesh, 2020). Essa capacidade torna o SVM uma opção valiosa para várias aplicações.

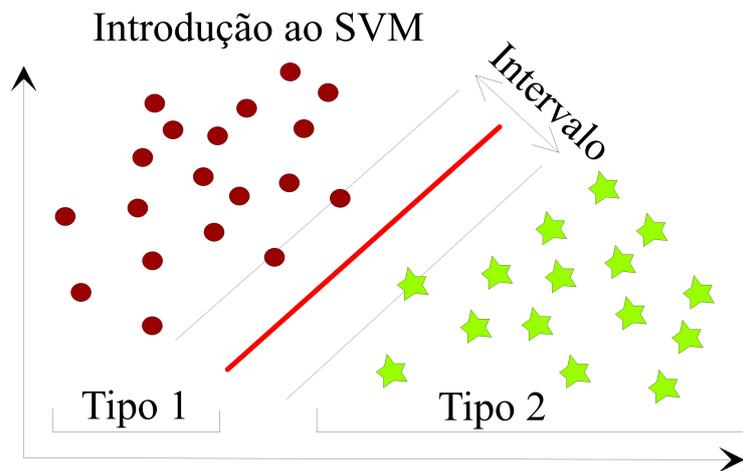


Figura 3.4: Esquema Suport Vector Machine (Mahesh, 2020)

A Floresta Randômica, também conhecida como Random Forest, é uma técnica que combina árvores de decisão e regressão. Ela cria uma "Floresta" de múltiplas árvores geradas a partir de amostras aleatórias dos dados. Cada árvore contribui com uma previsão, e a média dessas previsões é usada como a saída final do modelo (Pant et al., 2022).

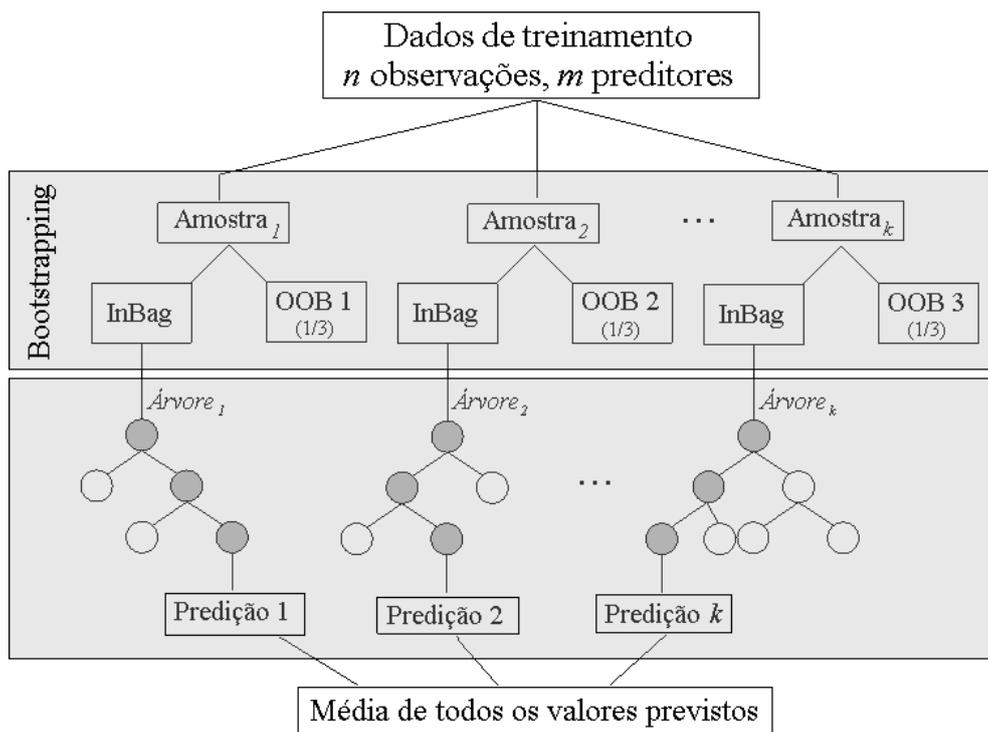


Figura 3.5: Esquema Floresta Randômica (Pant et al., 2022)

A Regressão Logística é uma técnica amplamente empregada para estimar a probabilidade de uma determinada instância pertencer a uma classe específica, como, por exemplo, a probabilidade de um *e-mail* ser classificado como spam ou não. Neste método de classificação binária, a instância é prevista como pertencente à classe positiva (rotulada como "1") se a probabilidade estimada for maior que 50%; caso contrário, é classificada como pertencente à classe negativa (rotulada como "0"). O modelo acrescenta um

termo de viés à soma ponderada das *features*, e em seguida, submetendo essa soma à função logística sigmoide, que transforma os valores resultantes em um intervalo entre 0 e 1. Essa interpretação probabilística possibilita uma previsão mais simples, com base no sinal do resultado obtido (Gerón, 2019).

O Algoritmo dos K-Vizinhos Mais Próximos (KNN) é uma técnica de classificação que se destaca por sua simplicidade e eficácia. Funciona com base na proximidade entre os dados e utiliza um conjunto de treinamento com rótulos para classificar novos dados. É especialmente útil em situações onde não há conhecimento prévio dos dados e é necessário determinar a classe de novas entradas. (Taunk et al., 2019)

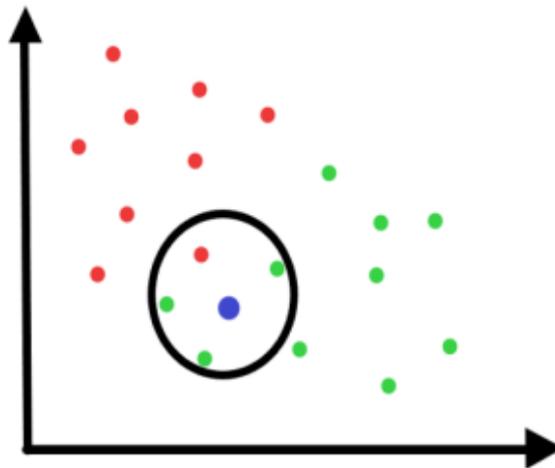


Figura 3.6: Simple exemplo de KNN (Taunk et al., 2019)

## 4 METODOLOGIA

A seguir, são descritas as atividades realizadas para o desenvolvimento da presente pesquisa, correspondente à metodologia implementada. Inicialmente, informações teóricas sobre o comportamento humano foram coletadas para compreender as características a serem avaliadas nos testes. Em seguida, é explicado o desenvolvimento das versões da bengala enativa, bem como os componentes incorporados nos dispositivos. Por fim, é detalhado o procedimento de execução dos testes realizados e os métodos de análise a serem utilizados.

### 4.1 **BACKGROUND EM ANATOMIA E ESTUDO DE SINAIS FISIOLÓGICOS**

Desenvolvimento de uma bengala com qualidades de um sistema enativo afetivo e analisar seu uso para avaliar risco de queda.

Para o desenvolvimento do projeto foi necessário realizar algumas pesquisas prévias referentes à anatomia humana e sinais fisiológicos, já que o entendimento desses temas é necessário para a interpretação de dados, e para a realização e validação de testes fisioterápicos. A seguir é sucintamente comentado duas características relevantes no monitoramento humano para o entendimento do presente estudo.

O sistema cardiovascular humano pode informar diversos dados importantes que são reflexos de respostas do sistema nervoso ou de outras atividades dos sistemas humanos e, por isso, deve-se ter um entendimento básico do mesmo. Exames de eletrocardiograma demonstram um sinal cíclico, ilustrando as atividades de diástole e sístole do coração. As características deste sinal, como a frequência entre os ciclos, formato dos picos, distância entre os picos e anomalias, carregam informações sensíveis sobre o funcionamento do corpo. Estudos relacionados ao sistema cardiorrespiratório mostram que a atividade respiratória perturba continuamente a hemodinâmica cardiovascular através de uma sequência de mecanismos diretos e indiretos (Aletti et al., 2009) indicam que a variabilidade da frequência cardíaca (HRV) tem sido apresentada como um dos marcadores mais promissores para a avaliação da regulação autonômica da função circulatória (Rocha et al., 2017).

O ato de caminhar permite às pessoas sua própria autonomia, possibilidade de fugir do perigo, desenvolver tarefas básicas e necessárias (comer, beber, trabalhar, locomoção), entre outras atividades. Porém, essa habilidade pode ser limitada ou comprometida em deficientes, pessoas com mobilidade reduzida e idosos. Intervenções fisioterapêuticas podem auxiliar na manutenção da marcha e deambulação, e alguns testes podem ser realizados para avaliar a qualidade da marcha e risco de queda. Entre os testes principais pode-se encontrar o TUG (*Timed Up and Go*) (Podsiladlo et al., 1991), a Escala de Equilíbrio de Berg (BERG et al., 1992) e a Escala de Equilíbrio e Marcha de Tinetti (TINETTI et al., 1990).

## 4.2 VERSÃO PRELIMINAR DA BENGALA

Uma vez compreendidos os conceitos teóricos nos quais o projeto da bengala enativa afetiva se baseiam e entender como a fisioterapia avalia marcha, deambulação e risco de queda, foi desenvolvida uma versão preliminar da bengala. Nesta etapa inicial, uma bengala comum de alumínio de ponto único e ajustável, foi enriquecida de sensores embarcados em seu corpo e controlados por um Arduino. Esta está representada na figura 4.1. O sistema foi embarcado com três grupos de sensores, divididos em módulo Locativos (que deveriam recuperar os dados referentes a localização espacial - sensores MPU-6050, HRCSR04 e FSR), módulo Ambientais (permitindo coletar informações do ambiente em que a bengala se encontrava - sensores DHT11 e LDR) e *M-Health* (relativo a sinais fisiológicos dos usuários - sensores GSR e PulseSensor).



Figura 4.1: Esboço conceitual da versão preliminar da bengala enativa afetiva (Autor)

O módulo locativo é composto pelos sensores MPU-6050, HRCSR04 e FSR. A Figura XX mostra o módulo do sensor MPU-6050 correspondente a um "Dispositivo de Rastreamento de Movimento" de 6 eixos. O sensor possui a combinação de um giroscópio de 3 eixos, um acelerômetro de 3 eixos e um "Processador de Movimento Digital". O giroscópio de 3 eixos está baseado na tecnologia Micro-Eletromecânica (MEMS) que detecta a velocidade de rotação ao longo dos eixos X, Y e Z. O acelerômetro de 3 eixos

apresenta tecnologia MEMS, que detecta o ângulo de inclinação ao longo dos três eixos. Na Figura 4.3, os eixos e polaridades do acelerômetro no MPU-6050 são mostrados. O Processador de Movimento Digital (DMP) integrado é usado para o cálculo dos protocolos de processamento de movimento, minimizando o esforço do hospedeiro na computação dos dados de movimento. Os dados de saída do DMP são lidos através de seus registradores. (Hassan, 2019)

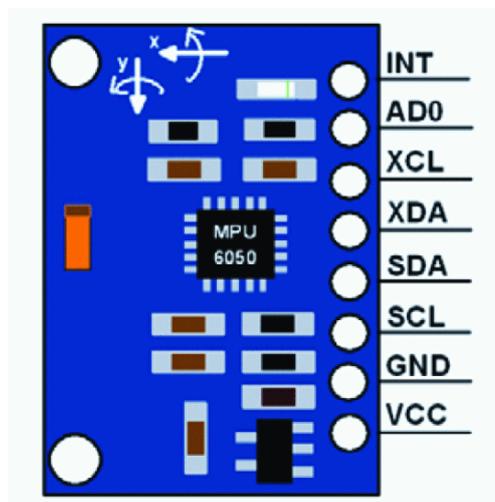


Figura 4.2: MPU-6050 (Hassan, 2019)

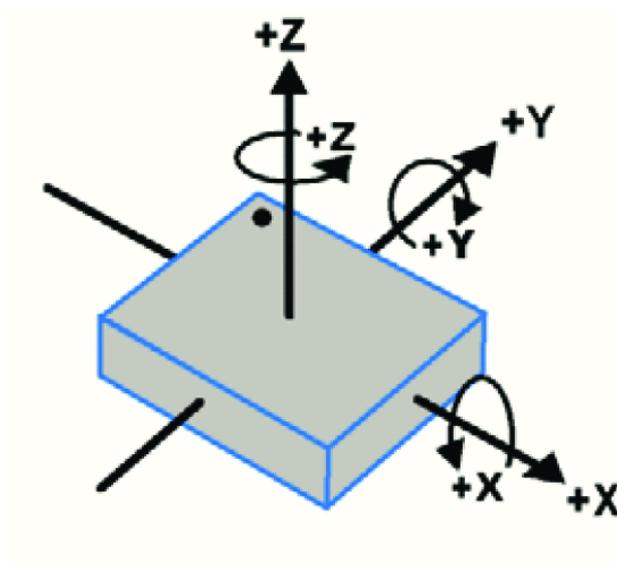


Figura 4.3: Orientação e polaridade de rotação do MPU-6050 (Hassan, 2019)

O sensor ultrassônico HC-SR04, ilustrado na figura 4.4, é capaz de medir distâncias de 2 centímetros a 2 metros ao enviar uma onda ultrassônica e calcular a distância medindo o tempo que a onda demora para voltar. A onda é emitida ao enviar um sinal para o *trigger* e aguarda-se até que a onda retorne. Este sensor pode calcular a distância da carenagem até o solo, permitindo observar padrões de marcha e deambulação, além de poder ajudar na identificação de possíveis quedas.



Figura 4.4: Sensor HRCRS04 (Autor)

Ilustrado na figura 4.5, o FSR (*Force Sensitive Resistor*), aplicado na base da bengala, é um sensor capaz de medir a pressão realizada pela bengala sobre o solo e fornecer informações precisas sobre o peso colocado no instrumento ao se locomover. De acordo a SAAD (2007) o ideal é que a bengala diminua a carga nos membros inferiores em no máximo 20 por cento do peso corporal. A resistência do sensor varia inversamente com a carga aplicada sob este, podendo demonstrar a força aplicada na bengala (Shaikh, 2015).

O módulo ambiental é composto por um módulo de temperatura e umidade relativa, chamado DHT11, e um sensor de luminosidade (LDR - *Light Dependent Resistor*/Resistor Dependente de Luminosidade). O sensor DHT11 (ver figura 4.5) possui saída de sinal digital que garante alta confiabilidade e estabilidade a longo prazo. O elemento sensor de temperatura é um termistor do tipo NTC e o sensor de Umidade é do tipo HR202, o circuito interno faz a leitura dos sensores e se comunica com um microcontrolador de bits de alta performance, oferecendo excelente qualidade, baixo tempo de resposta e ótimo custo benefício. A aquisição de dados deve ser realizada através de um sinal serial de uma via.

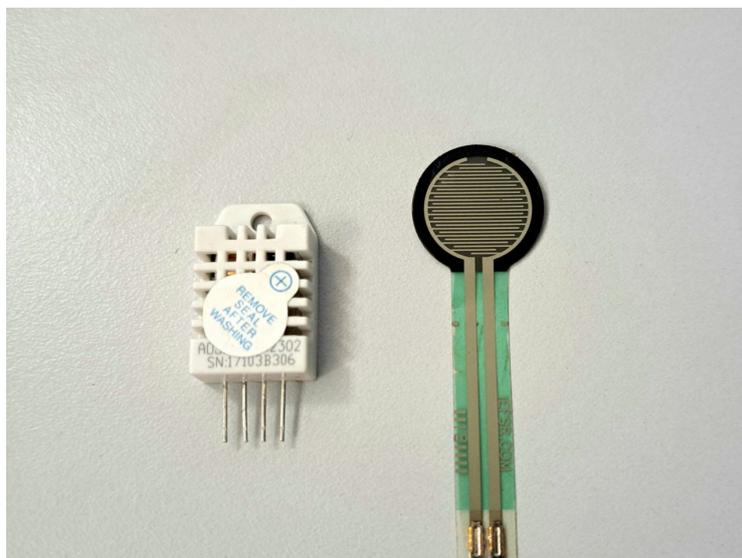


Figura 4.5: Sensor DHT11 à esquerda e sensor FSR à direita (Autor)

O LDR é um módulo que pode ser usado para avaliar a luminosidade de um ambiente. São usadas

duas células fotocondutivas de sulfeto de cádmio com resposta espectral similar ao do olho humano. A resistência da célula decresce com o aumento da intensidade de luz no ambiente (ver figura 4.5).

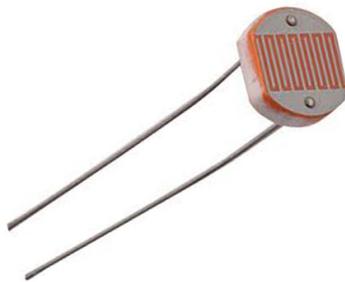


Figura 4.6: Sensor LDR (Xcluma)

O módulo *m-health* é composto de um sensor de resposta galvânica da pele (GSR Sensor) e um oxímetro de pulso (*PulseSensor*).

A resposta galvânica da pele é um método que permite medir a condutância elétrica da pele. Emoções podem estimular o sistema nervoso simpático, fazendo as glândulas sudoríparas secretarem mais suor. O sensor de resposta galvânica da pele (GSR), ilustrado na figura 4.7, permite capturar essas emoções simplesmente conectando dois eletrodos a dois dedos em uma mão e opera numa tensão entre 3,3V e 5V, sendo que a sensibilidade do mesmo é ajustada com o uso de um potenciômetro.

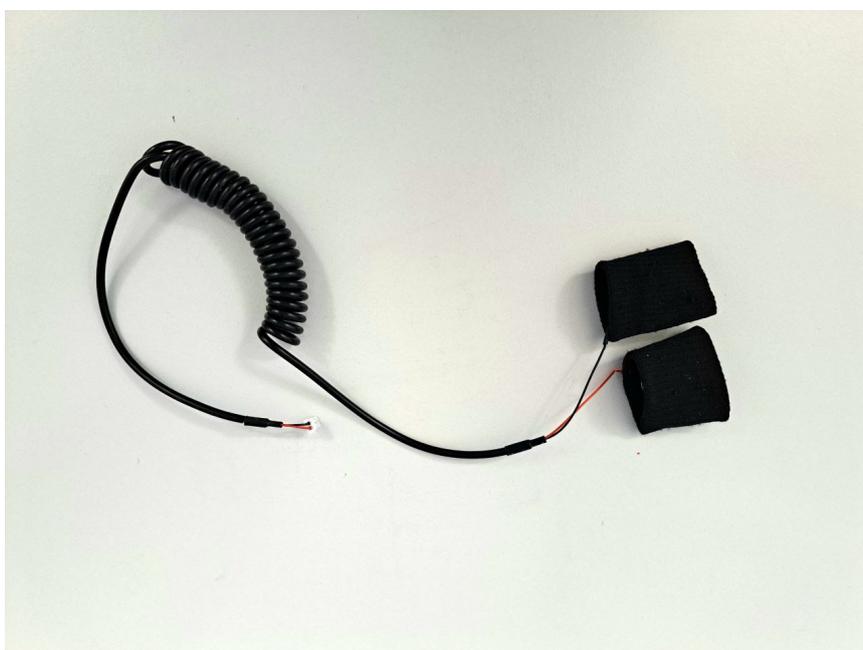


Figura 4.7: Sensor GSR V1.2 (Autor)

Por outro lado, o *PulseSensor* é um sensor de frequência cardíaca de baixo custo, *plug-and-play*, projetado para Arduino, incorporando de maneira fácil dados de frequência cardíaca ao vivo em seus projetos. Seu tamanho de botão permite seja facilmente preso às pontas dos dedos ou lóbulo da orelha, onde ele

realiza as mensurações. A figura 4.8 ilustra o *PulseSensor*.



Figura 4.8: *Pulse Sensor* (Autor)

Para a alimentação do circuito foram utilizadas duas baterias de 9 Volts e uma chave do tipo *switch* para ligar e desligar, que podem ser vistas na figura 4.9.

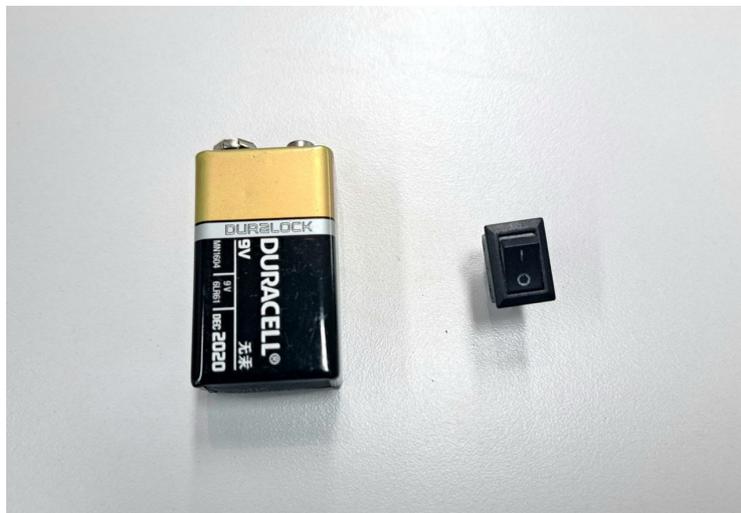


Figura 4.9: Exemplo de bateria de 9 volts e chave switch (Autor)

Na versão preliminar da bengala, todos os módulos eram controlados por um Arduino UNO, uma placa da plataforma *open-source* de eletrônicos Arduino, fácil de usar e flexível para diversas finalidades. Para programar a placa Arduino foi usada a IDE (*Integrated Development Environment*) *Arduino Software*, que possui bibliotecas nativas e *open-source*, expansíveis com bibliotecas C++. O módulo *bluetooth* HC-05, módulo porta serial do *bluetooth* que utiliza uma interface UART com *baud rate* programável com 6 pinos, foi usado para prover comunicação entre a bengala e algum dispositivo de análise (computador ou celular).

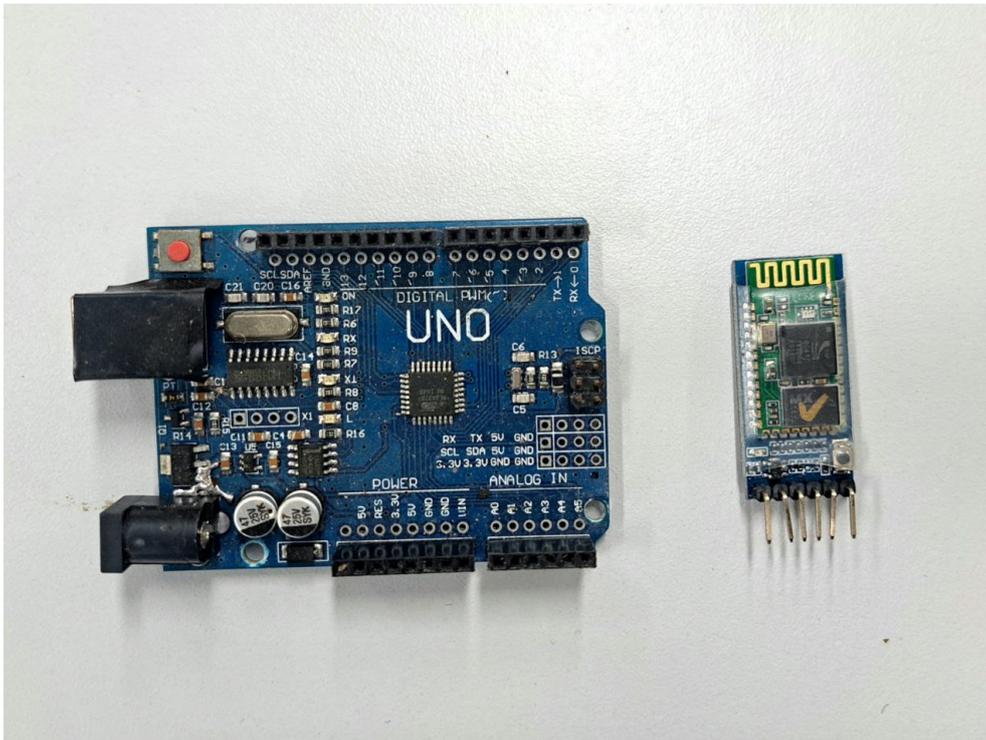


Figura 4.10: Arduino Uno à direita e o módulo *bluetooth* HC-05 à direita (Autor)

```
sketch_jul24a.ino
1 void loop()
2 {
3
4 int data;
5 int pck ;
6 float floatData;
7
8 if(CanRead[LOWER_TIMER])
9 {
10 //Read sequence.
11
12 #ifdef READ_OXIMETRY
13 data = analogRead(OXIMETRY_PORT);
14
15 rxData.push(1);
16 rxData.push(data);
17
18 #endif
```

Figura 4.11: Exemplo de código no Arduino IDE (Autor)



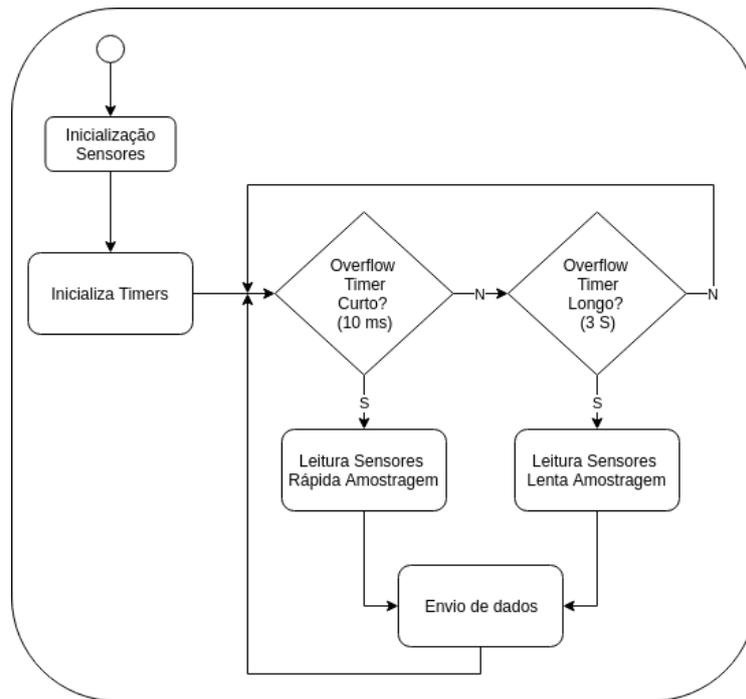


Figura 4.14: Fluxograma sobre taxa de amostragem do *firmware* para captura dos dados dos sensores de versão da bengala (Autor)

Um programa para computador, ilustrado na figura 4.15, foi criado com o *framework* QT para receber e arquivar os dados capturados em um banco de dados do tipo MySQL e auxiliar na execução de testes, já que este permitia visualizar em tempo “quase real” informações de alguns sensores. Também está ilustrado na figura 4.15 um exemplo de teste das ferramentas realizado pelo autor.

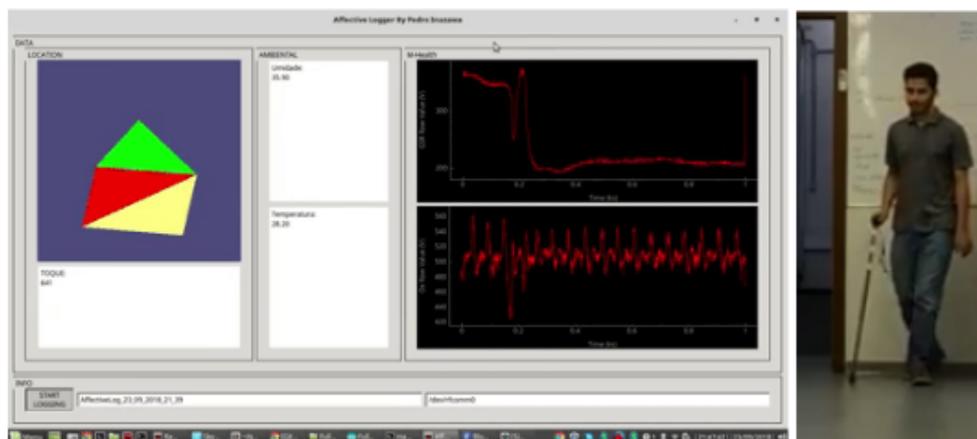


Figura 4.15: Programa de computador criado para visualização dos testes e armazenamento dos dados à esquerda e o autor realizando um teste à direita (Autor)

Após algumas avaliações, percebeu-se que os dados do oxímetro de pulso, do *Pulse Sensor*, não eram robustos quando obtidos por um usuário que segura uma bengala, pois a captura de dados fica inconsistente devido à variação de pressão do dedo sobre o sensor. Portanto, adicionalmente, foi incorporado um monitor cardíaco da marca Polar, como nó periférico do sistema, a fim de medir o comportamento do sistema

cardiovascular a partir de um sensor amplamente utilizado por atletas.



Figura 4.16: Monitor cardíaco Polar (Polar)

O monitor cardíaco funcionou bem e foi incorporado ao sistema como nó periférico da bengala enativa afetiva, já que o *firmware* do Arduino não capturava e armazenava os dados. Assim, alguns protocolos de testes foram estabelecidos para sincronizar a captura dos dados obtidos pelo Arduino UNO e pelo Polar. Devida a novas prioridades do grupo este sensor não foi profundamente explorado, mas há indícios de resultados promissores obtidos por ele para uma versão futura da bengala.

Pela grande quantidade de sensores e dados obtidos pela bengala enativa afetiva, observou-se um consumo grande de energia e instabilidades na comunicação *bluetooth* da bengala, inviabilizando a autonomia do sistema, necessária para a etapa de realização de testes, a ser realizada em seguida. Além disso, percebeu-se que o Arduino UNO já não atendia as necessidades da equipe, que procurava um microcontrolador mais poderoso para futuras perspectivas do sistema desenvolvido. Por fim, havia dificuldade de replicação do sistema para a realização de diversos testes simultâneos, já que haviam diferentes grupos colaborativos de trabalho espalhados pelo país. Estes motivos levaram à decisão de desenhar uma nova versão da bengala enativa afetiva.

### 4.3 SEGUNDA VERSÃO DA BENGALA

Foi estabelecida uma segunda etapa do equipamento da bengala a fim de desenvolver um sistema robusto, com dados mais precisos e consumo de bateria menor. Para isto, o sistema foi redesenhado, escolhendo um microcontrolador mais poderoso (ESP32). Adicionalmente todos os módulos de sensores foram reavaliados.

O protótipo atual possui um sistema embarcado de cerca de 200 gramas, o que configura um sistema leve, porém seu peso se aproxima ao peso próprio da bengala (300 gramas), concluindo que esse não é de pequenas dimensões, comparado com esta. No entanto, como este sistema perpassa a haste no centro da bengala, o efeito sobre o equilíbrio do objeto é minimamente alterado, pois existe uma simetria no sentido frente/costas e uma quase simetria no sentido direita/esquerda. Futuramente, espera-se reduzir consideravelmente o peso do sistema embarcado e construir uma versão totalmente simétrica.

O ESP32 é um poderoso microcontrolador do tipo SoC (System on Chip), com dois núcleos operando em diferentes frequências, podendo chegar a 240 MHz, que possui recursos integrados de *Bluetooth dual mode* versão 4.2, Wi-Fi 802.11 b/g/n e diversos periféricos. Além disso, o ESP32 também oferece 36 pinos GPIO, 16 canais PWM, e está equipado com 4MB de memória flash. Para escrever o *firmware*

deste microcontrolador pode-se usar o Arduino IDE. Existe um plugin criado pela próprio fabricante, o qual encontra-se disponível desde 2019 sob o nome “*Arduino core for ESP32 WiFi chip*” no GitHub, que provê suporte aos projetos criados para o microcontrolador no ambiente de desenvolvimento integrado da Arduino (Babiuch, 2019).

Devido às características do acelerômetro e giroscópio, estes são amplamente empregados em várias aplicações de detecção de quedas, combinando seus dados para aprimorar o funcionamento e a confiabilidade do sistema (Silva, 2018). A primeira atividade a explorar corresponde à avaliação do risco de quedas, tendo assim que o módulo locativo foi o primeiro a ser reincorporado na bengala, com o sensor MPU-6050, já que este provê informações sobre a posição espacial da bengala.

Adicionalmente, os sensores FSR e DHT11 foram logo incorporados novamente à bengala, devido à sua simplicidade de funcionamento e dados preciosos para futuras análises do grupo. A temperatura e umidade podem alterar comportamentos humanos e Hinde et al. (2017) sugerem que variações na temperatura podem causar alterações na marcha e na postura. Analisar a força realizada contra o chão pode dar informações complementares sobre a deambulação do usuário de bengala, já que compreender a biomecânica da marcha assistida por bengala é de suma importância para aprimorar as intervenções terapêuticas para reabilitação (Kamono, 2018).

As figuras 4.17, 4.18, 4.19 e 4.20 demonstram a versão atual da bengala enativa afetiva.



Figura 4.17: Protótipo da Bengala Enativa Afetiva (Autor)

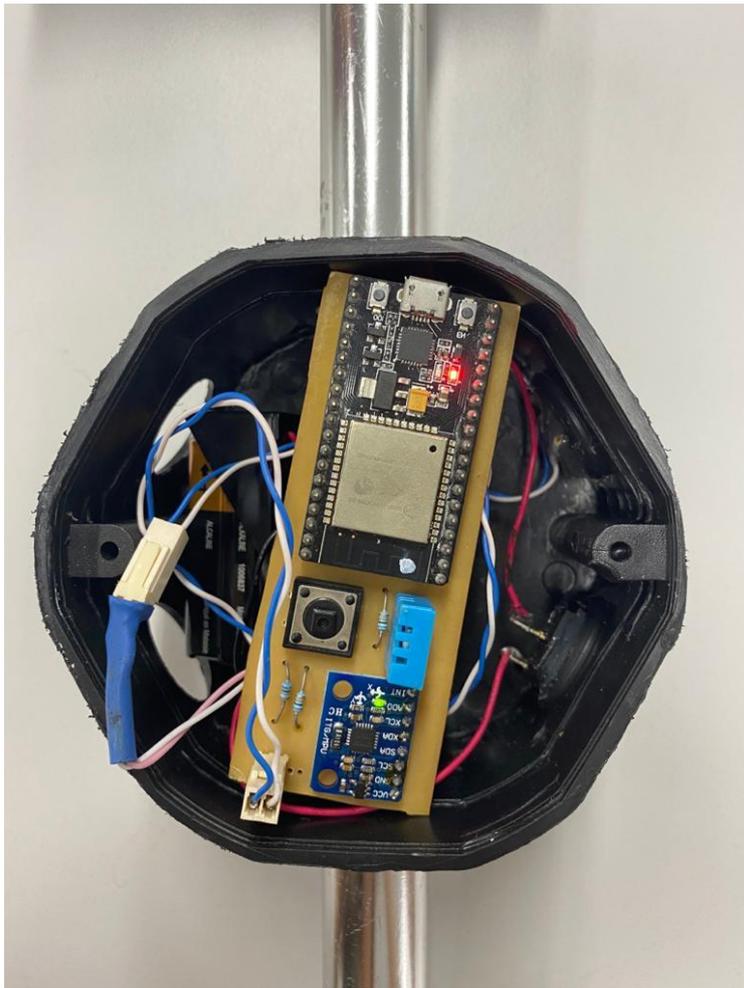


Figura 4.18: Visão interna do dispositivo (Autor)



Figura 4.19: Interface externa do dispositivo (Autor)

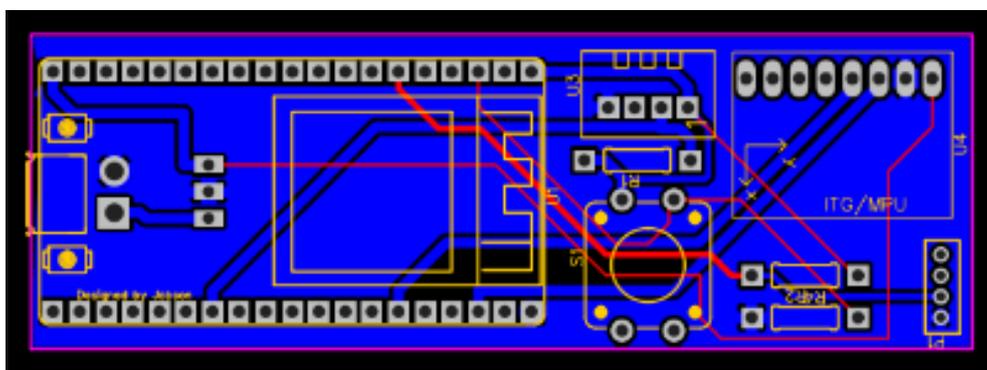


Figura 4.20: Esquemático de placa de circuito impresso criado para a nova versão da bengala (Autor)

Para atestar o bom funcionamento dos sensores, foram feitos alguns testes de bancada, avaliando o funcionamento dos sensores.

#### 4.4 EXPERIMENTOS DE AVALIAÇÃO DA BENGALA: ESTUDO PILOTO

Assim como (Saleh, 2021), que utiliza um dispositivo vestível para identificar quedas, decidiu-se investigar o uso da bengala para identificação de padrões de marcha e avaliação do risco de queda de idosos. Para isto, alguns testes com idosos foram programados. Inicialmente foi submetido um pedido no Comitê

de Ética em Pesquisa em Ciências Humanas e Sociais que foi aprovado.

Recomendado pelas Sociedades Americanas e Britânicas de Geriatria (Greene et al., 2010), o teste escolhido para o estudo preliminar se chama *Timed Up and Go* (TUG) e mede o tempo que uma pessoa leva para se levantar de uma cadeira padrão, caminhar 3 metros, fazer uma volta e sentar-se novamente. Ele pode usar calçados e auxílios de locomoção habituais, como uma bengala, se for necessário. Nenhuma assistência física é fornecida, e antes de ser cronometrado, o indivíduo realiza o teste uma vez para se familiarizar com o procedimento. O desempenho pode ser medido com qualquer cronômetro ou relógio com precisão de segundos. (Podsildlo et al., 1991).

A avaliação da marcha em idosos é um marcador crucial. Vários estudos destacam a importância da avaliação clínica da marcha como um indicador significativo do estado de saúde em populações idosas (Ostir et al., 2015). Nesse contexto, a velocidade de marcha tem sido reconhecida como uma ferramenta de triagem potencialmente adequada para identificar precocemente indivíduos com maior risco de queda (Lusardi, 2012; Middleton et al., 2015).

No artigo original de Podsildlo et al. (1991) foi demonstrado que o tempo de execução do teste TUG está diretamente relacionado ao risco de queda, ou seja, quanto mais rápido o teste é realizado, menor é o risco de queda. Um experimento completo com indivíduos de uma Instituição de longa permanência de idosos no Distrito Federal foi realizado, mas a análise dos dados revelou um erro na formatação, tornando-os inutilizáveis. A repetição do experimento foi inviável devido à pandemia da COVID-19.

A solução alternativa foi conduzir testes simulados com voluntários hígidos em laboratório e optou-se em se medir variáveis relacionadas ao tempo de execução do teste TUG, ou seja, com a celeridade dos movimentos. Já que não é possível fazer um teste direto correlacionando o movimento com o risco de queda, três pessoas, duas do sexo masculino e uma do sexo feminino, de 22 a 26 anos, participaram do teste piloto em laboratório simulando diferentes velocidades de marcha com o auxílio da bengala enativa afetiva. Os voluntários foram instruídos pela fisioterapeuta M.a. Amabylli Mikaele Costa Luz sobre como uma bengala deve ser utilizada e os testes foram dirigidos por ela.

A cadeira utilizada nos testes era do tipo sem braço, desprovida de estofamento e com altura de 45 cm. O trajeto consistia em uma caminhada em linha reta de 3 metros com uma indicação visual do ponto de término. Os experimentos foram realizados em terreno plano, sem obstáculos, e cada participante sentou na cadeira com as costas apoiadas. Um comando verbal foi utilizado como método para início do teste e ao escutá-lo cada usuário deveria levantar-se e caminhar até uma linha no chão, viravam-se e retornavam à cadeira, sentando-se novamente e apoiando-se no encosto. Os participantes utilizaram seu calçado habitual e não receberam assistência física, tendo a bengala afetiva ajustada à altura de cada voluntário. Um cronômetro foi utilizado para registrar o tempo de execução. A figura 4.21 demonstra o trajeto do teste.



Figura 4.21: Trajeto dos testes realizados (Autor)

Os testes conduzidos com os três voluntários hígidos contemplavam três faixas distintas de velocidades (conforme detalhado na tabela 4.1), com o propósito de obter dados representativos de caminhadas que pudessem ser classificadas em diferentes níveis de risco: risco baixo de queda (menos de 10 segundos), risco moderado (entre 10 e 20 segundos) e risco elevado (mais de 20 segundos) (Podsildlo et al., 1991; Wall et al., 2000). Essa abordagem permitiu capturar uma variedade de cenários de caminhada, considerando seus potenciais graus de risco associados, conforme estabelecido pela literatura especializada.

Tabela 4.1: Classificação de velocidades dos testes

Velocidade Simulada	Risco Associado	Tempo t (segundos)
Rápida	Baixo	$t < 10$
Intermediária	Moderado	$10 < t < 20$
Lenta	Alto	$20 < t < 30$

Os resultados foram capturados por meio do terminal serial de um *smartphone* com sistema operacional Android e gravados em alguns arquivos de log que foram utilizados para análise, como exemplificado na figura 4.22.

```

2 21:56:58.329 ax 988 ay -15996 az -2056 gx -258 gy -6129 gz 4246
3 21:56:58.384 ax 3716 ay -16176 az -1664 gx 252 gy -3781 gz 4863
4 21:56:58.453 ax 3704 ay -15848 az -1432 gx 844 gy 1120 gz 6332
5 21:56:58.522 ax 2220 ay -15948 az -748 gx 1334 gy 4401 gz 7739
6 21:56:58.564 ax 760 ay -14880 az -636 gx 1415 gy 7114 gz 8900
7 21:56:58.631 ax -5152 ay -15188 az 10032 gx -827 gy 4385 gz 8660
8 21:56:58.685 ax -5552 ay -15164 az 2096 gx -4661 gy -12900 gz 6979
9 21:56:58.758 ax -8532 ay -16008 az 640 gx -3372 gy -10891 gz 6390
10 21:56:58.884 ax -3520 ay -31144 az 3944 gx -8598 gy -20138 gz -161
11 21:56:58.886 ax -1128 ay -19748 az 1972 gx -11951 gy -23032 gz -3176
12 21:56:58.960 ax -2820 ay -12472 az 120 gx -13638 gy -24944 gz -8848
13 21:56:59.041 ax -2100 ay -15276 az -1344 gx -11236 gy -17056 gz -12208
14 21:56:59.102 ax -1916 ay -15512 az -832 gx -9988 gy -14033 gz -12182
15 21:56:59.178 ax 500 ay -16900 az 408 gx -3492 gy -9677 gz -12374
16 21:56:59.255 ax 736 ay -16724 az 2228 gx 3062 gy -6509 gz -12098
17 21:56:59.318 ax 1216 ay -15196 az 4492 gx 6680 gy -10019 gz -11417
18 21:56:59.397 ax 1656 ay -14680 az 5096 gx 8124 gy -13426 gz -10524
19 21:56:59.405 ax 1292 ay -15704 az 4180 gx 8544 gy -17774 gz -9089
20 21:56:59.476 ax 1860 ay -17456 az 4520 gx 9208 gy -16148 gz -5106
21 21:56:59.540 ax 524 ay -14812 az 5216 gx 7583 gy -15828 gz -1797
22 21:56:59.609 ax 252 ay -15968 az 3660 gx 3761 gy -21032 gz -1665

```

Figura 4.22: Exemplo de log capturado

Os sinais da unidade inercial foram amostrados a uma frequência de 20 Hz e divididos em janelas com intervalos de 15 amostras e com uma sobreposição (*overlap*) de 80%. Essas janelas foram utilizadas para computar diversas características tanto no domínio do tempo quanto no domínio da frequência, incluindo: média, valor RMS médio, variância, distância cumulativa da média, assimetria da distribuição e energia das maiores componentes da Transformada Rápida de Fourier do sinal. Essas características foram essenciais para o processamento dos dados e permitiram uma análise detalhada das informações obtidas durante os testes.

Após a realização de testes preliminares, foi decidido reagrupar as três faixas de velocidades utilizadas nos experimentos em apenas duas categorias de saída possíveis: "caminhada lenta" e "caminhada rápida". Essa modificação consistiu em combinar as duas classes com o resultado do TUG mais alto em apenas uma, ou seja, a "caminhada lenta". Essa escolha foi realizada com o intuito de obter uma melhor padronização e facilidade de comparação entre todos os testes realizados. Assim, cada uma das janelas de cada experimento foi rotulada de acordo com a sua categoria correspondente. Ao unificar as faixas de velocidades mais elevadas em uma única categoria, tornou-se possível simplificar a análise e a interpretação dos resultados, permitindo uma comparação mais direta e consistente entre os diferentes experimentos. Essa abordagem facilita a identificação de padrões e tendências, bem como a compreensão geral do desempenho do modelo em relação às caminhadas realizadas pelos voluntários. Ao concluir a rotulagem, as janelas foram distribuídas em dois grupos: 90% para treinamento e 10% para validação. As características computadas de cada janela foram utilizadas como entrada para seis métodos de aprendizado: Regressão logística, *Support Vector Machine* (SVM), Árvore de Decisão, *Random Forest*, K Vizinhos próximos e Naives Bayes. Para fins de análise, opta-se por utilizar resultados binários, onde apenas duas opções de saída foram consideradas.

O objetivo do teste é estabelecer uma prova de conceito, demonstrando a viabilidade do uso de técnicas de aprendizado de máquina para detectar variáveis que permitam estimar o risco de queda. É importante salientar que este é apenas um algoritmo inicial, sendo que a expectativa é avançar em trabalhos futuros,

desenvolvendo algoritmos mais robustos e sofisticados para a detecção. Além disso, espera-se que no futuro haja o desenvolvimento de formas mais eficientes de transmitir as informações estimadas ao usuário da bengala. Essa abordagem visa complementar a função da bengala, transformando-a em uma interface enativa, capaz de fornecer informações relevantes e em tempo real sobre o risco de queda. Esse aprimoramento visa tornar a bengala uma ferramenta ainda mais valiosa e eficaz para auxiliar e proteger os usuários em suas atividades cotidianas.

## 5 RESULTADOS

Neste capítulo, são apresentados os valores obtidos nos testes realizados, conforme especificado na metodologia. Além disso, são mostradas as análises dos métodos de aprendizagem de máquina aplicados. Por fim, é feita a interpretação dos resultados encontrados.

No gráfico apresentado na figura 5.1, apresenta-se o tempo cronometrado para cada TUG, realizado pelos três voluntários saudáveis, em diferentes intervalos de velocidades propostas:

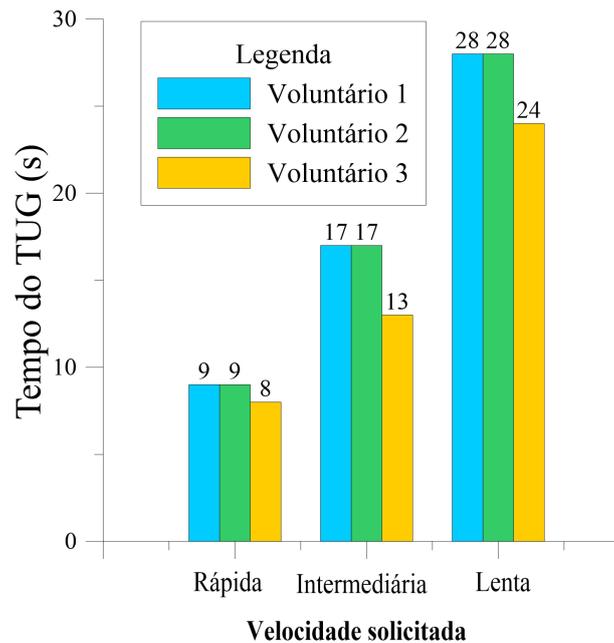


Figura 5.1: Gráfico de resultados do TUG

Na tabela 5.1, são exibidos os índices obtidos para precisão, revocação, F1-Score e suporte para cada modelo de aprendizado, bem como para cada atividade analisada. Ademais, são destacadas a média micro (micro avg), média macro (macro avg) e média ponderada (weighted avg). Esses dados consolidados proporcionam uma visão abrangente e detalhada da performance dos modelos em relação às atividades estudadas.

Modelos	Rótulo	Precisão	Revocação	F1-Score	Suporte
Árvore de decisão	Cam. Rapida	0.88	0.90	0.89	137.00
	Cam. Lenta	0.94	0.93	0.94	244.00
	micro avg	0.92	0.92	0.92	381.00
	macro avg	0.91	0.92	0.91	381.00
	weighted avg	0.92	0.92	0.92	381.00
Floresta Randômica	Cam. Rapida	0.73	0.53	0.61	137.00
	Cam. Lenta	0.77	0.89	0.83	244.00
	micro avg	0.76	0.76	0.76	381.00
	macro avg	0.75	0.71	0.72	381.00
	weighted avg	0.76	0.76	0.75	381.00
KNN	Cam. Rapida	0.77	0.74	0.75	137.00
	Cam. Lenta	0.86	0.87	0.86	244.00
	micro avg	0.82	0.82	0.82	381.00
	macro avg	0.81	0.81	0.81	381.00
	weighted avg	0.82	0.82	0.82	381.00
Naive Bayes	Cam. Rapida	0.53	0.23	0.32	137.00
	Cam. Lenta	0.67	0.89	0.76	244.00
	micro avg	0.65	0.65	0.65	381.00
	macro avg	0.60	0.56	0.54	381.00
	weighted avg	0.62	0.65	0.61	381.00
Regressão Logística	Cam. Rapida	0.30	0.33	0.31	137.00
	Cam. Lenta	0.60	0.57	0.59	244.00
	micro avg	0.49	0.49	0.49	381.00
	macro avg	0.45	0.45	0.45	381.00
	weighted avg	0.50	0.49	0.49	381.00
SVM	Cam. Rapida	0.00	0.00	0.00	137.00
	Cam. Lenta	0.64	1.00	0.78	244.00
	micro avg	0.64	0.64	0.64	381.00
	macro avg	0.32	0.50	0.39	381.00
	weighted avg	0.41	0.64	0.50	381.00

Tabela 5.1: Índices obtidos de cada algoritmo

Destaca-se o F1-Score como a métrica-padrão escolhida, uma vez que essa medida valoriza os resultados corretos como um todo, penalizando tanto os falsos positivos como os falsos negativos. Além disso, adotou-se a micro-média como padrão para os resultados das classes, considerando-a uma métrica mais sensível para bases de dados desbalanceadas. Com base nessas avaliações, é possível obter uma visão aprofundada da eficácia dos modelos em estudo. Na tabela 5.2, encontram-se as matrizes de confusão.

Entrada Saída	Caminhada Rápida		Caminhada Lenta	
	Caminhada Rápida	Caminhada Lenta	Caminhada Rápida	Caminhada Lenta
Árvore de decisão	123	14	11	233
Floresta Randômica	72	65	26	218
KNN	101	36	31	213
Naive Bayes	32	105	28	216
Regressão Logística	45	92	104	140
SVM	0	137	0	244

Tabela 5.2: Matrizes de confusão

Os resultados indicam que o modelo de aprendizado com máquina de vetor de suporte (SVM) tende a classificar a maioria dos eventos como caminhada lenta, enquanto falha em detectar adequadamente os eventos de caminhada rápida. Dessa forma, o classificador não atingiu um desempenho adequado para a tarefa em questão. Essa conclusão é reforçada pelos valores nulos nos coeficientes de precisão, revocação e F1-Score relacionados à caminhada rápida, evidenciando sua incapacidade de corretamente identificar essa atividade.

Observa-se, em relação ao desempenho do modelo de regressão logística, que embora ele tenha sido bem-sucedido em identificar a caminhada lenta corretamente, mostrou uma falha significativa ao classificar corretamente uma caminhada rápida como tal. Além disso, uma grande quantidade de caminhadas rápidas foi erroneamente classificada como lentas, e o mesmo ocorreu com caminhadas lentas sendo identificadas erroneamente como rápidas. Essas características também foram evidenciadas pelos baixos valores dos coeficientes de precisão, revocação e F1-Score.

Quando o modelo de aprendizado com floresta randômica foi utilizado, os resultados mostraram uma boa capacidade de captar a caminhada lenta, porém apenas uma captura moderadamente boa para a caminhada rápida. Esse método foi classificado como o terceiro melhor desempenho entre os algoritmos avaliados.

Os resultados obtidos pelo modelo de aprendizado do tipo vizinho mais próximo demonstram um desempenho satisfatório na detecção tanto da caminhada rápida quanto da caminhada lenta. No entanto, quando comparado ao método de árvore de decisão, esse modelo apresentou um desempenho ligeiramente inferior. Para a caminhada lenta, os valores de precisão, revocação e F1-Score foram de 0.86, 0.87 e 0.86, respectivamente. Já para a caminhada rápida, os valores foram de 0.77, 0.74 e 0.75, respectivamente. Os falsos negativos em ambos os casos foram relativamente baixos, mas o desempenho ficou um pouco aquém do alcançado pelo modelo de árvore de decisão. Desse modo, esse modelo pode ser considerado o segundo melhor em termos de desempenho geral.

O modelo de aprendizado do tipo Naive Bayes não apresentou resultados muito promissores. Para a atividade de caminhada lenta, os índices de precisão, revocação e F1-Score foram, respectivamente, 0.67, 0.89 e 0.76, indicando um desempenho moderadamente bom. Entretanto, para a caminhada rápida, os valores foram bem inferiores, registrando precisão de apenas 0.53, revocação de 0.23 e F1-Score de 0.32. Esses resultados apontam que o método não permitiu a captura efetiva da caminhada rápida, mostrando suas limitações na detecção dessa atividade específica. Os resultados evidenciados na Tabela ?? claramente indicam um excelente desempenho do classificador baseado em árvore de decisão. Tanto para a detecção

de caminhada rápida, quanto para a caminhada lenta, os valores de precisão, revocação e F1-Score foram próximos ou superiores a 90%. Adicionalmente, o número de falsos positivos e falsos negativos foi notavelmente baixo. Esse algoritmo, utilizando árvore de decisão, destacou-se como o de melhor desempenho dentre todos os algoritmos testados.

É importante ressaltar que os experimentos realizados e a análise apresentada não foram exaustivos e não esgotaram todas as possibilidades que podem ser exploradas. Há diversas outras variáveis que podem ser investigadas, com a extração de diferentes características (*features*). Além disso, outros modelos de aprendizado podem ser empregados, bem como diferentes estratégias e ajustes podem ser testados para os mesmos algoritmos. Essas possibilidades permanecem abertas para investigação futura. Os resultados obtidos nesta etapa sugerem que ainda há espaço para avanços significativos no processo de detecção e previsão de quedas. Portanto, é desejável realizar mais testes com idosos, a fim de aprimorar e refinar os modelos desenvolvidos, buscando resultados ainda mais promissores.

O estudo serve como uma base sólida e promissora para futuras pesquisas, possibilitando a evolução contínua da detecção de quedas e o aperfeiçoamento das estratégias de cuidados preventivos em relação à marcha e ao risco de queda em idosos. Outros módulos da bengala, como os sensores ambientais, não foram adequadamente testados devido a dificuldades com a testagem em diferentes ambientes. No entanto, tanto a autora deste trabalho quanto a equipe acreditam que esses aspectos podem se revelar relevantes quando forem incluídos em testes com usuários reais da bengala. A perspectiva é que a realização de testes com usuários reais possibilitará uma avaliação mais completa e precisa desses recursos, permitindo uma compreensão mais abrangente do seu potencial e eficácia.

## 6 CONCLUSÃO

Este trabalho se fundamenta na teoria enativa de cognição incorporada, inspirada nos pensamentos de Varela e Maturana. Explorando os conceitos dos sistemas enativos afetivos, investiga-se a interação entre seres humanos, tecnologias e ambiente, aprimorando a mobilidade e a saúde por meio da cognição incorporada, compreendendo como o ser humano afeta e é afetado pelo mundo. O projeto visou contribuir para uma compreensão mais profunda e criativa das interações humanas com o ambiente, abrindo caminho para inovações em diversas áreas do conhecimento.

Neste projeto final de graduação são apresentados o desenvolvimento de dois protótipos da bengala enativa afetiva. Bengalas comuns, de alumínio e ajustáveis, foram instrumentadas com microcontroladores e sensores organizados em três módulos (locativo, espacial e *mhealth*) que garantiam a robustez e confiabilidade dos dados devido à variabilidade de informações. Devido à grande quantidade de sensores presentes no protótipo inicial da bengala enativa afetiva, observou-se um consumo grande de energia, inviabilizando a autonomia energética do sistema necessária para a etapa de testes prevista. Esta etapa também foi limitada devido a inconsistências na comunicação *bluetooth* do primeiro protótipo, que apresentava falhas durante a movimentação do objeto. Além disso, percebeu-se que o Arduino UNO já não atendia as necessidades da equipe, que procurava um microcontrolador mais poderoso para futuras perspectivas do sistema desenvolvido. Por fim, havia dificuldade de replicação do sistema para a realização de diversos testes simultâneos, já que haviam diferentes grupos colaborativos de trabalho espalhados pelo país.

Uma nova versão de bengala foi desenvolvida com um microprocessador ESP32, mais poderoso e mais compacto que o Arduino UNO. O novo microprocessador inclui um módulo para comunicação *bluetooth* integrado, que evita inconsistências na transferência dos dados enviados pela bengala para o dispositivo que captura essas informações. Os sensores MPU-6050, FSR e DHT11 foram reinsertos à versão devido a suas relevâncias e facilidades de integração, enquanto novos sensores de todos os módulos devem ser inseridos numa versão aprimorada do protótipo. A atual versão se destaca por ser mais eficiente em consumo de energia, mais simples em termos de manutenção de software e hardware, além de oferecer maior confiabilidade nos dados, pois seguiu-se um planejamento para minimizar os possíveis vieses na captura, aumentando a estabilidade do processo. Adicionalmente observou-se uma maior facilidade na replicação de novos protótipos, otimizando os tempos de trabalho da equipe.

Foram realizados testes piloto para avaliação de risco de queda, utilizando os dados obtidos a partir do TUG para confrontar diferentes classificadores. Seis algoritmos de aprendizado de máquina foram comparados em termos de performance na classificação de padrões de marcha. As análises dos modelos de aprendizado de máquina para detecção de caminhada rápida e lenta revelaram resultados distintos. A regressão logística falhou ao classificar corretamente ambas as atividades, enquanto o vetor de suporte teve dificuldades na identificação da caminhada rápida. A árvore de decisão destacou-se como o melhor algoritmo, com alta precisão, revocação e F1-Score para ambas as atividades. A floresta randômica obteve desempenho moderado, e o vizinho mais próximo foi o segundo melhor em desempenho geral. O Naive Bayes apresentou limitações na detecção da caminhada rápida, com resultados insatisfatórios. Em resumo, a árvore de decisão foi a opção mais eficaz, destacando-se entre os algoritmos testados.

Para que a bengala atual obtenha qualidade de sistema enativo afetivo são necessários alguns aprimoramentos no hardware e software da mesma, a fim de que se torne um sistema invisível ao usuário, provendo cognição incorporada. Espera-se que no futuro o protótipo seja capaz de não apenas classificar com precisão diferentes padrões de marcha para a avaliação de risco de queda, mas que utilize dados de mais sensores e algoritmos para prever quedas e, mais que isso, seja capaz de fornecer ao usuário feedbacks sobre sua deambulação e riscos de queda, além de ser capaz de fazer mais interpretações sobre como este afeta o seu ecossistema e é afetado por este.

## 7 REFERÊNCIAS

- ABRAHAM, A. Artificial neural networks. Handbook of measuring system design, John Wiley & Sons, Ltd Chichester, UK, 2005.
- ALENCAR, P. d. et al. Fatores de risco associados às quedas em idosos e reflexões acerca de sua prevenção: um estudo de revisão. Arch Health Invest, v. 6, n. 1, 2017.
- ALPAYDIN, E. Introduction to machine learning. [S.l.]: MIT press, 2020.
- BABIUCH, M.; FOLTÝNEK, P.; SMUTNÝ, P. Using the esp32 microcontroller for data processing. In: IEEE. 2019 20th International Carpathian Control Conference (ICCC). [S.l.], 2019. p. 1–6.
- BERG, K. O.; MAKI, B. E.; WILLIAMS, J. I.; HOLLIDAY, P. J.; WOOD- DAUPHINEE, S. L. Clinical and laboratory measures of postural balance in an elderly population. Archives of physical medicine and rehabilitation, Elsevier, v. 73, n. 11, p. 1073–1080, 1992.
- JASON BROWNLEE. Linear Regression for Machine Learning. Disponível em:<https://machinelearningmastery.com/linear-regression-for-machine-learning/>.
- DOMINGUES, D. M. G. Re-encanto do concreto por sistemas enativos afetivos: a naturalização das tecnologias no ecossistema. PORTO ARTE: Revista de Artes Visuais, v. 24, n. 40, 2019.
- FAUSETT, L. V. Fundamentals of neural networks: architectures, algorithms and applications. [S.l.]: Pearson Education India, 2006.
- GÉRON, A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. [S.l.]: "O'Reilly Media, Inc.", 2019.
- GitHub “Arduino core for ESP32 WiFi chip”, 2019. Disponível em: <https://github.co/esp8266/arduino-esp32.m>
- GREENE, B. R.; ODOVANO, A.; ROMERO-ORTUNO, R.; COGAN, L.; SCANAILL, C. N.; KENNY, R. A. Quantitative falls risk assessment using the timed up and go test. IEEE Transactions on biomedical Engineering, IEEE, v. 57, n. 12, p. 2918–2926, 2010.
- HASSAN, A.; LIU, Z.; ABBAS, S. S.; LI, Y.; WANG, L.; LIU, X.; ZHAO, P. Statistical scheme for fault detection using arduino and mpu 6050. In: IEEE. 2019 Prognostics and System Health Management Conference (PHM-Qingdao). [S.l.], 2019. p. 1–7.
- HAYKIN, S. Neural networks: a comprehensive foundation. [S.l.]: Prentice Hall PTR, 1998.
- HINDE, K.; LLOYD, R.; LOW, C.; COOKE, C. The effect of temperature, gradient, and load carriage on oxygen consumption, posture, and gait characteristics. European journal of applied physiology, Springer, v. 117, p. 417–430, 2017.
- JIANG, J. A survey of machine learning in additive manufacturing technologies. International Journal of Computer Integrated Manufacturing, Taylor & Francis, p. 1–23, 2023.

KAMONO, A.; KATO, M.; OGIHARA, N. Accuracy evaluation of a method to partition ground reaction force and center of pressure in cane-assisted gait using an instrumented cane with a triaxial force sensor. *Gait & posture*, Elsevier, v. 60, p. 141–147, 2018.

KAPANDJI, A. I. *Anatomia Funcional Vol. 2 - Membro Inferior*. 6. ed. [S.l.]: Guanabara Koogan, 2012. v. 2. 2918–2926 p. 36

KARUKA, A. H.; SILVA, J. A.; NAVEGA, M. T. Análise da concordância entre instrumentos de avaliação do equilíbrio corporal em idosos. *Brazilian Journal of Physical Therapy*, SciELO Brasil, v. 15, p. 460–466, 2011.

LIMA-COSTA, M. F. et al. Cohort Profile: The Brazilian Longitudinal Study of Ageing (ELSI-Brazil). *International Journal of Epidemiology*, 24 jun. 2022.

LUSARDI, M. M. Using walking speed in clinical practice: interpreting age-, gender-, and function-specific norms. *Topics in Geriatric Rehabilitation*, LWW, v. 28, n. 2, p. 77–90, 2012.

LUZ, Amabylli Mikaele Costa. *A bengala afetiva: sistema enativo afetivo voltado para a saúde do idoso*. 2020. xii, 62 f., il. Dissertação (Mestrado em Engenharia Biomédica)—Brasília, 2020.

MAGLOGIANNIS, I. G. *Emerging artificial intelligence applications in computer engineering: real word ai systems with applications in ehealth, hci, information retrieval and pervasive technologies*. [S.l.]: Ios Press, 2007. v. 160.

MAHESH, B. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], v. 9, n. 1, p. 381–386, 2020.

MIDDLETON, A.; FRITZ, S. L.; LUSARDI, M. Walking speed: the functional vital sign. *Journal of aging and physical activity*, Human Kinetics, Inc., v. 23, n. 2, p. 314–322, 2015.

OSTIR, G. V.; BERGES, I.; KUO, Y.-F.; GOODWIN, J. S.; OTTENBACHER, K. J.; GURALNIK, J. M. Assessing gait speed in acutely ill older patients admitted to an acute care for elders hospital unit. *Archives of internal medicine*, American Medical Association, v. 172, n. 4, p. 353–358, 2012.

O’SULLIVAN, S. B.; SCHMITZ, T. J. *Fisioterapia: avaliação e tratamento*. In: *Fisioterapia: avaliação e tratamento*. [S.l.: s.n.], 2010. p. 1506–1506.

PANT, A.; RAMANA, G. Novel application of machine learning for estimation of pullout coefficient of geogrid. *Geosynthetics International*, Thomas Telford Ltd, v. 29, n. 4, p. 342–355, 2022.

PIMENTEL, W. R. T. et al. Falls among Brazilian older adults living in urban areas. *Revista de Saúde Pública*, v. 52, n. Suppl 2, p. 12s, 24 jan. 2019.

PENTLAND, A.; LAZER, D.; BREWER, D.; HEIBECK, T. Using reality mining to improve public health and medicine. In: *Strategy for the Future of Health*. [S.l.]: IOS Press, 2009. P. 93–102.

PODSIADLO, D.; RICHARDSON, S. The timed up & go: a test of basic functional mobility for frail elderly persons. *Journal of the American geriatrics Society*, Wiley Online Library, v. 39, n. 2, p. 142–148, 1991.

PORTA, A.; ALETTI, F.; VALLAIS, F.; BASELLI, G. Multimodal signal processing for the analysis

of cardiovascular variability. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, The Royal Society London, v. 367, n. 1887, p. 391–409, 2009.

RAY, S. A quick review of machine learning algorithms. In: IEEE. 2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon). [S.l.], 2019. p. 35–39.

RUSSELL, S. J. *Artificial intelligence a modern approach*. [S.l.]: Pearson Education, Inc., 2010.

SAAD, M. Meios auxiliares de marcha. In: GREVE, J. M. D. (Ed.). *Tratado de medicina de reabilitação*. São Paulo: Roca, 2007. p. 330–333.

SALEH, M.; ABBAS, M.; PRUDHOMM, J.; SOMME, D.; JEANNES, R. L. B. A reliable fall detection system based on analyzing the physical activities of older adults living in long-term care facilities. *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 29, p. 2587–2594, 2021.

SHAHIN, M. A.; JAKSA, M. B.; MAIER, H. R. State of the art of artificial neural networks in geotechnical engineering. *Electronic Journal of Geotechnical Engineering*, v. 8, n. 1, p. 1–26, 2008.

SHAIKH, M. F.; SALCIC, Z.; WANG, K. Analysis and selection of the force sensitive resistors for gait characterisation. In: IEEE. 2015 6th International Conference on Automation, Robotics and Applications (ICARA). [S.l.], 2015. p. 370–375.

SILVA, E. K. R. *Desenvolvimento de um sistema de detecção de quedas para idosos*. Universidade Estadual da Paraíba, 2018.

TAUNK, K.; DE, S.; VERMA, S.; SWETAPADMA, A. A Brief Review of Nearest Neighbor Algorithm for Learning and Classification. 2019 International Conference on Intelligent Computing and Control Systems (ICCS), Madurai, India, 2019, pp. 1255-1260, 2019.

TINETTI, M. E.; RICHMAN, D.; POWELL, L. Falls efficacy as a measure of fear of falling. *Journal of gerontology*, The Gerontological Society of America, v. 45, n. 6, p. P239–P243, 1990.

VARELA, F. J. *Steps to a science of inter-being: Unfolding the dharma implicit in modern cognitive science. The psychology of awakening*, Rider/Random House New York, p. 71–89, 1999.

VARELA, F. J.; THOMPSON, E.; ROSCH, E. *The embodied mind, revised edition: Cognitive science and human experience*. [S.l.]: MIT press, 2017.

WALL, J. C.; BELL, C.; CAMPBELL, S.; DAVIS, J. The timed get-up-and-go test revisited: measurement of the component tasks. *Journal of rehabilitation research and development*, v. 37, n. 1, 2000.