



GABRIEL EDMILSON PINTO

**APLICAÇÃO DE INTERNET DAS COISAS NA
IDENTIFICAÇÃO E MONITORAMENTO DE MOVIMENTOS
EM EXERCÍCIOS FÍSICOS COM PESOS LIVRES**

**LAVRAS - MG
2023**

GABRIEL EDMILSON PINTO

**APLICAÇÃO DE INTERNET DAS COISAS NA IDENTIFICAÇÃO E
MONITORAMENTO DE MOVIMENTOS EM EXERCÍCIOS FÍSICOS COM PESOS
LIVRES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência da Computação, área de concentração em Sistemas de Computação, para a obtenção do título de Mestre.

Prof. Dr. Tales Heimfarth
Orientador

Prof. Dr. João Carlos Giacomin
Coorientador

**LAVRAS - MG
2023**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Pinto, Gabriel Edmilson.

Aplicação de Internet das Coisas na Identificação e
Monitoramento de Movimentos em Exercícios Físicos com Pesos
Livres / Gabriel Edmilson Pinto. - 2023.

74 p.

Orientador(a): Tales Heimfarth.

Coorientador(a): João Carlos Giacomini.

Dissertação (mestrado acadêmico) - Universidade Federal de
Lavras, 2023.

Bibliografia.

1. Internet das Coisas. 2. Reconhecimento de Movimentos. 3.
Academias Inteligentes. I. Heimfarth, Tales. II. Giacomini, João
Carlos. III. Título.

GABRIEL EDMILSON PINTO

**APLICAÇÃO DE INTERNET DAS COISAS NA IDENTIFICAÇÃO E
MONITORAMENTO DE MOVIMENTOS EM EXERCÍCIOS FÍSICOS COM PESOS
LIVRES**

**INTERNET OF THINGS APPLICATION FOR MONITORING AND IDENTIFYING
FREE WEIGHT EXERCISES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência da Computação, área de concentração em Sistemas de Computação, para a obtenção do título de Mestre.

APROVADA em 28 de Fevereiro de 2023

Profa. Dra. Renata Lopes Rosa UFLA
Prof. Dr. Sandro Pereira da Silva UFLA
Prof. Dr. Álvaro César de Oliveira Penoni UFSJ

Prof. Dr. Tales Heimfarth
Orientador

Prof. Dr. João Carlos Giacomini
Coorientador

**LAVRAS - MG
2023**

à Raimunda Emiliorelli Marques (In memoriam)

Dedico.

AGRADECIMENTOS

À Universidade Federal de Lavras (UFLA), especialmente ao Departamento de Ciência da Computação (DCC), pela oportunidade concedida para realização do mestrado.

Ao Professor Dr. Tales Heimfarth pela orientação, confiança, parceria e direcionamento imprescindível para este projeto ter acontecido. Ao Professor Dr. João Carlos Giacomini pela coorientação e votos assertivos nos momentos em que estive criativamente bloqueado com a pesquisa, sem os quais eu não teria conseguido concluí-la de tal forma. Aos Professores do Departamento de Ciência da Computação que atuam com tanto amor na missão de ensinar.

Às minhas famílias de sangue e de escolha pelo amparo e sustentação emocional. Ao meu avô Oswaldo pelo exemplo de perseverança; aos meus pais por entenderem os caminhos que escolhi; aos meus irmãos de caminhada Jenifer, Carol e Jean pela fundação espiritual de grande amizade.

À Fraternidade Águas de Maria e a todos os seus fraternos pela navegação e pelo refúgio, aos meus mais velhos por terem escutado antes o chamado, ao amor que a tudo prospera, à família que a tudo sustenta e à liberdade que a tudo faz valer a pena.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

MUITO OBRIGADO!

“O conhecimento é a maior riqueza que se almeja e saber utilizá-lo é ser rico eternamente.”

(Provérbio Cigano)

RESUMO

Em um mundo cada vez mais integrado aos meios digitais, um novo recurso de comunicação tecnológica tem recebido mais visibilidade: a internet das coisas (*Internet of Things* – IoT). Esse recurso trata-se de imbuir de sensores sem fio os dispositivos utilizados no dia a dia da sociedade com o intuito de facilitar a comunicação e explorar a capacidade dessas ferramentas na otimização de tarefas. Este trabalho integrou a internet das coisas no monitoramento de atividades físicas com foco no uso de pesos livres (anilhas), visando auxiliar praticantes e treinadores por meio de uma análise dos movimentos executados identificando exercícios através dos dados dos sensores. Este reconhecimento se deu pelo uso de algoritmos de aprendizado de máquina como árvores de decisão, perceptron multi-camadas e kNN, treinados para reconhecer padrões na movimentação dos pesos. As anilhas foram sensorizadas com um microcontrolador ESP8266 e um sensor inercial MPU-6050 calibrado através de métodos de posição e filtros digitais. Os microcontroladores enviam os dados a um servidor através de comunicação por socket por meio de uma rede local, no servidor os dados são organizados e guardados, posteriormente aplicando processamentos e executando os algoritmos para classificar os exercícios. Os algoritmos se mostraram eficazes na identificação dos exercícios, alcançando acurácias superiores a 90% nos melhores casos. Essa aplicação possibilita treinamentos remotos e ou assíncronos de forma efetiva, não invasiva e com baixo custo.

Palavras-Chave: *IoT*. Reconhecimento de movimentos. Academias inteligentes.

ABSTRACT

In a world increasingly integrated with digital media, a new technological communication resource has received more visibility: the Internet of Things (IoT). This feature consists of imbuing wireless sensors in devices used in the daily life of society to facilitate communication and explore the capacity of these tools in optimizing tasks. This paper integrates the IoT in the monitoring of physical activities with a focus on the use of free weights (weight plates), aiming to assist practitioners and coaches through an analysis of the performed movements and identifying exercises through the data read. This recognition was achieved through the use of machine learning algorithms such as decision trees, multi-layer perceptron, and kNN, trained to recognize patterns in the movement of weights. The plates were sensed with an ESP8266 microcontroller and an MPU-6050 inertial sensor calibrated with positional methods and digital filters. The microcontrollers send data to a server in the local network using socket communication. In the server, data are received, recorded, processed, and passed to the algorithms to accomplish the classification process which identified the exercises efficiently, achieving accuracies superior to 90% for the best cases. Therefore, this application brings great potential to make remote and asynchronous training efficiently possible, not invasive, and with a low cost.

Keywords: IoT. Movement recognition. Smart gyms.

LISTA DE FIGURAS

Figura 1.1 – Beleza corporal: Ânfora grega. Ática, século IV A.E.C.	17
Figura 2.1 – Representação do movimento de impulso e resistência	23
Figura 2.2 – Protótipo de tecnologia vestível que identifica temperatura corporal . . .	27
Figura 2.3 – Sistema vestível para reabilitação da articulação dos cotovelos	30
Figura 2.4 – Espaço amostral e conjuntos amostrais	32
Figura 2.5 – Estrutura de uma árvore de decisão	35
Figura 2.6 – Arquitetura de MLP com duas camadas ocultas	38
Figura 2.7 – MLP de camada oculta única, <i>features</i> e saída neutra	38
Figura 2.8 – Classificação em <i>kNN</i> de 3 classes com <i>k</i> igual a 5	40
Figura 4.1 – ESP8266 sobre Protoboard	47
Figura 4.2 – MPU-6050	47
Figura 4.3 – Bateria e carregador	48
Figura 4.4 – Módulo Shield Bateria 18650 para ESP32	48
Figura 4.5 – Anilhas	49
Figura 4.6 – Anilha sensorizada em atividade e pegada	49
Figura 4.7 – Infraestrutura de comunicação	52
Figura 4.8 – Comunicação via <i>socket</i>	52
Figura 4.9 – Execução de exercício: tríceps francês	53
Figura 4.10 – Execução de exercício: rosca direta	53
Figura 4.11 – Execução de exercício: desenvolvimento de ombros	54
Figura 4.12 – Execução de exercício: passada	54
Figura 4.13 – Visualizador de rotações alimentado pela saída de dados do MPU-6050 .	57
Figura 4.14 – Filtro duplo de média aplicado aos eixos do giroscópio para a passada . .	59
Figura 5.1 – Gráfico de acurácia geral usando amostragem de média simples	62
Figura 5.2 – Gráfico de acurácia geral usando amostragem de média de composição .	63
Figura 5.3 – Exemplo de árvore de decisão gerada pelo <i>scikit-learn</i>	64

LISTA DE QUADROS

2.1	Vantagens e desvantagens das árvores de decisão	37
2.2	Vantagens e desvantagens das RNAs	39
2.3	Vantagens e desvantagens dos kNNs	41
3.1	Comparação entre os trabalhos relacionados e o trabalho proposto.	42
4.1	Amostra de dados coletada a cada leitura	55
5.1	Configurações dos algoritmos	60

LISTA DE TABELAS

Tabela 4.1 – Exemplo de leitura quando o sensor está parado	50
Tabela 4.2 – Quantificação de coletas realizadas	56
Tabela 5.1 – Acurácia geral dos algoritmos usando amostragem de média simples . . .	61
Tabela 5.2 – Acurácia geral dos algoritmos usando amostragem de média de composição	62

LISTA DE ALGORITMOS

2.1 Exemplo do uso de um <i>estimator</i> e método <i>fit</i> com a <i>scikit-learn</i>	34
---	----

LISTA DE SIGLAS

IoT	Internet das Coisas – <i>Internet of Things</i>
IHRSA	International Health, Racquet & Sportsclub Association
IMU	Unidade de Medição Inercial – <i>Inertial Measurement Unit</i>
WHO	World Health Organization
ML	Aprendizado de Máquina – <i>Machine Learning</i>
RNA	Rede Neural Artificial
MLP	Perceptron multicamadas – <i>Multi-layer Perceptron</i>
kNN	K Vizinhos Mais Próximos – <i>K Nearest Neighbors</i>

LISTA DE SÍMBOLOS

D_E	Distância Euclidiana
D_M	Distância Manhattan
S	Espaço amostral
f	Conjunto amostral ou <i>feature</i>
mA	Miliampère, unidade de medida da intensidade da corrente elétrica
mAh	Miliampère hora, denota capacidade de baterias
V	Volt(s), unidade de medida de tensão elétrica
σ	Offset, o valor de desvio em relação a um valor esperado
g	Constante da aceleração da gravidade $\approx 9,8m/s^2$
g	Variável de filtro de aceleração gravitacional de cada eixo do acelerômetro
α	Constante para filtragem digital da interferência gravitacional

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	18
1.2	Motivação e justificativa	19
1.3	Problema de pesquisa	19
1.4	Organização deste documento	21
2	REFERENCIAL TEÓRICO	22
2.1	Aceleração gravitacional e forças de impulsão e resistência	22
2.2	Corpo e movimento	24
2.3	Internet das coisas	25
2.3.1	Sensores inerciais e microcontroladores	28
2.4	Análise do movimento e algoritmos de classificação	29
2.4.1	Aprendizado de máquina e <i>scikit-learn</i>	32
2.4.2	<i>Decision Tree (DT)</i>	34
2.4.3	<i>Multi-layer Perceptron (MLP)</i>	36
2.4.4	<i>K Nearest Neighbours (kNN)</i>	39
3	TRABALHOS RELACIONADOS	42
4	METODOLOGIA	46
4.1	Equipamentos	46
4.2	Calibragem e comunicação	50
4.3	Exercícios analisados	51
4.4	Coleta de dados	55
4.5	Visualização	56
4.6	Preparação dos dados e classificação dos exercícios	57
5	RESULTADOS	60
6	CONCLUSÃO	65
6.1	Contribuição e trabalhos futuros	65
	REFERÊNCIAS	66

1 INTRODUÇÃO

A prática de atividades físicas desempenhou papel fundamental na sobrevivência do ser humano primitivo por meio da caça de alimento e da fuga de predadores (RAMOS, 1983) até que, com o surgimento das civilizações, das religiões e da guerra, o preparo físico passou a ser uma ferramenta de culto e poder (ALMEIDA et al., 2012). Foi na Grécia Antiga, como apontam Ferreira (2004) e Nascimento e Nascimento (2019), onde surgiram as primeiras competições estruturadas e com regras bem definidas, realizadas em homenagem aos deuses. Nestes eventos, os guerreiros mais poderosos e os atletas mais talentosos construíram o arquétipo do herói mítico, i. e. seres humanos que se aproximavam do divino, uma referência marcante para a sociedade da época, principalmente para a parcela mais jovem (MACHADO, 2006).

Onde existe a necessidade de determinada prática, também há de existir um local apropriado para ela. Estruturas formadas por campos abertos e pequenas edificações religiosas originam os primeiros locais de prática das atividades físicas, conhecidos como ginásios. Chaline (2015, p. 9, grifo nosso) define o ginásio como: “[...] lugar onde o corpo é transformado por meio da prática física, especialmente por diferentes formas de exercício¹” e divide os treinamentos físicos em duas categorias de acordo com o objetivo esperado de sua prática:

- a) treinamento estético, onde o intuito é o de atingir um ideal de beleza corporal por meio da modelação do corpo e definição muscular (retratado em artes como a da Figura 1.1);
- b) treinamento complementar ou auxiliar, o intuito é tonificar o corpo para objetivos atléticos como melhoria de resistência, vitalidade, força, coordenação e agilidade.

Estabelecer uma rotina de atividades físicas, atualmente, transcende as categorias de treino citadas acima. Nas últimas décadas, estudos têm indicado impactos positivos da prática regular de atividades físicas na prevenção, manutenção, reabilitação e melhoria em diversas áreas da saúde humana, como: humor (CHAN et al., 2019); cognição (ROLLAND; ABELLAN VAN KAN; VELLAS, 2008); sistema cardiovascular (RAINERIE; KELLERMANN, 1983); ansiedade e depressão (WHITE et al., 2017). De fato, segundo a World Health Organization (2018), níveis adequados e regulares de atividades físicas melhoram a saúde muscular, cardiorrespiratória e óssea, além de reduzir o risco de hipertensão, diabetes e vários tipos de câncer.

¹A Organização Mundial da Saúde (*World Health Organization*) define o exercício como uma subcategoria de atividade física que é planejada, estruturada e repetitiva, com o objetivo de melhorar ou manter um ou mais componentes de aptidão física.

Figura 1.1 – Beleza corporal: Ânfora grega. Ática, século IV A.E.C.



Fonte: Chaline (2015a).

De acordo com Capinussú (2006), as instituições privadas ligadas à prática de atividades físicas no Brasil surgiram a partir de 1890 com o primeiro clube oficial de ginástica do país. Após essa data, várias modalidades de clubes começaram a surgir destinados a alguma prática específica, como: natação, artes marciais, dança e halterofilismo. Isso fez com que o mercado de *fitness* passasse a ser atrativo para mais pessoas. Segundo relatório da International Health, Racquet & Sportsclub Association (IHRSA, 2017), um levantamento realizado em 2016 estimou que haviam 201 mil academias no mundo e que a receita do mercado *fitness* tenha alcançado US\$ 83,1 bilhões, sendo o Brasil o segundo país com mais academias no mundo (34.509) e décimo em receita (US\$2,1 bilhões) – reflexo do cenário econômico do país.

Esse cenário complicado, porém promissor, sofreu um grande impacto no ano de 2020: a pandemia de COVID-19 fez com que as academias interrompessem suas atividades sem previsão de retorno. Para contornar essa fase desafiadora, academias ao redor do mundo passaram a tentar negociar acordos com os clientes ou investir em aulas virtuais (ACAD, 2020). Entretanto, a adaptação dos treinos para exercícios que não dependam do aparato das academias, possibilitando o treino remoto, não é uma tarefa trivial. Não só o acompanhamento do usuário pelo treinador como também as modalidades mais dependentes de ferramentas de treino (como o caso da musculação) ficaram prejudicadas. Essas circunstâncias revelaram pontos fracos do mercado *fitness* que costumava-se ignorar: o que resta além do local físico para a prática e como promover acompanhamento profissional remotamente. De fato, é de conhecimento comum que

durante os horários de pico² os profissionais de educação física têm dificuldade de acompanhar com precisão todos os usuários.

Um meio tecnológico intermediário entre o treinador, o usuário e as atividades físicas tem o potencial de cobrir os pontos descritos, contudo, só a intermediação não resolveria o problema da adaptação remota dos treinos para modalidades como a musculação. Felizmente, nem todos os equipamentos de uma academia são inviáveis de se ter em casa, principalmente para praticantes assíduos desse tipo de atividade física. Esses equipamentos mais acessíveis são os pesos livres, um grupo de equipamentos formado por halteres, anilhas, barras e outros pesos de fácil mobilidade. Por fim, ainda seria necessário que os exercícios físicos envolvendo esses equipamentos fossem devidamente monitorados e as informações precisariam estar acessíveis aos treinadores, de forma assíncrona.

Hoje em dia a tecnologia faz parte do cotidiano das pessoas e os chamados “objetos inteligentes (*smarts*)” como os *smarthphones*, as *smart TVs*, os *smartwatches*, dentre outros, têm sido muito familiares – nunca o ser humano esteve mais conectado. Uma das novas tecnologias em grande crescimento atualmente é a internet das coisas (*Internet of Things* - IoT), descrita por Santos et al. (2016) como uma extensão da internet conhecida, tendo o objetivo de realizar a conectividade entre objetos com capacidade computacional de oferecer serviços úteis para diversas atividades humanas, sendo uma significativa tendência de mercado dos últimos anos, como reforça Routh e Pal (2018), devido à sua capacidade de conectar objetos físicos de forma automatizada para trabalharem nas atividades do dia-a-dia, reduzindo o esforço e expandindo a capacidade humana.

1.1 Objetivos

O objetivo geral deste projeto foi avaliar uma aplicação de internet das coisas capaz de coletar dados referentes à atividades físicas, processá-los e identificar, por meio de inteligência artificial, qual exercício físico foi realizado.

Os objetivos específicos deste projeto foram:

- a) montar uma solução de baixo custo capaz de ser extensível à várias aplicações destinadas à áreas da saúde;
- b) configurar uma infraestrutura de comunicação eficiente;
- c) apresentar uma aplicação com um nível de acurácia elevado e, portanto, confiável;

²Horários com alta concentração de pessoas no recinto.

1.2 Motivação e justificativa

Sem dúvidas, a prática regular de atividades físicas é um dos fatores indispensáveis para que uma população se mantenha sadia. No entanto, nos anos anteriores à pandemia já se verificava grande dificuldade em manter as pessoas motivadas a se exercitarem, principalmente em exercícios de musculação executados nas academias de forma rotineira e repetitiva. Segundo Karvitz (2011), a prática de atividades físicas realizadas dessa forma faz com que o usuário se sinta entediado rapidamente, o que conseqüentemente o faria desistir de continuar com os treinos. O ambiente lotado das academias também é um fator desmotivacional pela dificuldade de receber acompanhamento minucioso dos educadores físicos que faz com que exercícios sejam realizados de forma aparentemente correta, porém não tão efetiva como deveria, levando a poucos resultados – o que não atinge as expectativas do praticante, frustrando-o.

É questão de tempo para chegar-se a um patamar de comunicação abrangente e inclusivo, que possibilite interconexões profundas voltadas para o aprimoramento da qualidade de vida da humanidade. Em vista de percepções como essa e das tecnologias emergentes que estão a surgir, este trabalho é motivado pela falta de contribuições na literatura voltadas especificamente para o monitoramento de atividades físicas em módulos de alto grau de liberdade³ como a calistenia e formas de treino fora da academia, com equipamentos acessíveis e não invasivos, uma vez que tecnologias que precisam ser vestidas podem atrapalhar a movimentação natural do corpo humano.

Ferramentas de acompanhamento da evolução do usuário poderiam ser um fator motivador por conta da visualização da execução da atividade, e a análise do procedimento poderia encontrar e corrigir precocemente pontos que impedem o usuário de evoluir nos seus objetivos, fornecendo dados para tomadas de decisão que auxiliariam nas estratégias de treino. Além disso, uma tecnologia como a proposta neste trabalho poderia ser aplicada a outras áreas da saúde como a fisioterapia, medicina e educação física, aprimorando ferramentas e métodos de reabilitação do movimento.

1.3 Problema de pesquisa

As academias possuem um grande apelo quanto a estabelecer um senso de comunidade por meio de interações sociais entre os praticantes e, além disso, produzem uma sensação de

³Movimentos que são livres, deslocando-se nos três eixos de coordenada conforme execução do usuário sem limitação de maquinários ou outros mecanismos além do corpo humano.

segurança na execução dos exercícios que são supervisionados por treinadores capacitados. Porém, também são ambientes propensos à super lotações, o que prejudica a supervisão dos profissionais, além de que o compartilhamento de equipamentos é um fator que torna propício o contágio de infecções (NYENHUIS et al., 2020). Levando em conta as novas tecnologias que vêm emergindo nas últimas décadas, diversas aplicações podem ser construídas e exploradas com o objetivo de melhorar as condições de saúde e esporte (PINTO; ROSA; RODRÍGUEZ, 2021), incluindo uma melhoria e adaptação da rotina de exercícios físicos, de forma que possa ser feita assincronamente e tornando seu acompanhamento ainda mais eficiente.

A internet das coisas é uma dessas tecnologias mencionadas acima, sendo capaz de estabelecer uma conexão mais precisa em relação às atividades de treino, possibilitando um controle eficaz e melhor gerenciável para os educadores físicos em relação aos seus alunos. Outra tecnologia a ser levada em consideração são os dispositivos móveis, aparelhos como *tablets* e *smartphones* que vêm se tornando cada vez mais acessíveis e populares (HORVATH et al., 2020). A união dessas duas tecnologias possibilita o desenvolvimento de um novo recurso atualmente pouco explorado para o mercado *fitness*: aplicações capazes de gerenciar, identificar e monitorar atividades físicas por meio da integração com sensores sem-fio imbuídos nos equipamentos ou no ambiente.

Diferente do maquinário das academias, que possui local fixo e formas de movimento estáticas, exercícios com pesos livres são realizados com total liberdade em relação aos três eixos dimensionais, além do tipo de exercícios. Por exemplo, uma máquina de *leg press* é voltada para exercícios específicos de membros inferiores que compartilham similaridades na execução, já uma anilha pode ser usada em exercícios de supinação, de agachamento, desenvolvimento de ombros, entre outros. Assim, tem-se um desafio muito grande com a correta análise e coleta dos dados. Além disso, os sensores são suscetíveis a erros que se mal cuidados podem comprometer os resultados da aplicação, inviabilizando sua funcionalidade.

Como levantado por Hassan et al. (2018), sensores inerciais tem sido muito utilizados na computação ubíqua para identificação de atividades humanas que demandam repetição, exatamente o que este trabalho propõe uma vez que exercícios físicos de musculação são baseados em repetir movimentos, porém com pesos. Todo exercício é composto de dois movimentos principais e antagônicos que podem ser facilmente entendidos como um movimento de ida e um de volta, sempre formando uma alavanca com as articulações do corpo humano. Assim, propõe-se instalar sensores inerciais nos pesos livres de forma a analisar e identificar esses movimentos.

Essa abordagem oferece uma alternativa remota, segura, assíncrona e eficaz para a prática de atividades físicas, melhorando a eficiência de seus procedimentos dentro até das próprias academias; também possibilitando a sua utilização por pessoas que já realizavam suas atividades físicas em casa e querem melhorar os resultados dos seus treinos; ou por pessoas que desejam iniciar a prática regular de exercícios físicos, mas não se sentem confortáveis ou cativadas em relação a frequentarem uma academia. Esta pesquisa também abre um caminho integrativo entre tecnologia e atividade física, um encontro entre uma prática muito antiga (antes realizada apenas com o peso do próprio corpo) com abordagens de uma era moderna com dispositivos inteligentes que automatizam e melhoram os rendimentos do treinamento.

1.4 Organização deste documento

Esta dissertação encontra-se organizada em seis partes, sendo esta seção de introdução a primeira parte, onde contextualizou-se o tema da pesquisa, os motivos que levaram à sua execução, apresentação das dores de mercado relacionadas e do problema abordado, objetivos definidos e organização do texto; a segunda parte trata das discussões encontradas na literatura sobre o tema e assuntos relevantes para a concepção do projeto como algoritmos e áreas correlatas; a terceira parte trata dos trabalhos relacionados; a quarta parte dos equipamentos, métodos, formas de coletar os dados e como se deram as preparações; a quinta trata dos resultados obtidos; a sexta parte apresenta as conclusões do projeto bem como as contribuições e possibilidades futuras; por fim tem-se a lista de referências utilizadas e apêndice.

2 REFERENCIAL TEÓRICO

Nesta seção serão apresentados os principais tópicos teóricos envolvendo a pesquisa, levantados pela revisão da literatura. A primeira seção aborda uma breve conceitualização sobre as forças atuantes na leitura dos sensores; a segunda seção trata do tema de internet das coisas, base do desenvolvimento desta pesquisa, também apresenta os conceitos de sensores inerciais e microcontroladores que serão utilizados; a terceira seção aborda estudos da área do corpo e do movimento, como fisiologia do exercício, cinesiologia e biomecânica; a quarta e última seção aborda o uso de sensores no reconhecimento de movimentos e suas tecnologias envolvidas, como a inteligência artificial para classificação dos movimentos.


2.1 Aceleração gravitacional e forças de impulsão e resistência

Exercícios com pesos livres possuem graus de liberdade que não podem ser resumidos em termos da velocidade média. Com um referencial de três dimensões no espaço e com deslocamentos a velocidades diferentes entre essas dimensões durante um mesmo período de tempo, percebe-se que há uma formação estruturada em eixos que precisam ser avaliados individualmente, e a cada instante estão em uma velocidade diferente. Essa variação da velocidade se dá pelo que chamamos de aceleração. Segundo Sears et al. (2008, p. 41), da mesma forma que a velocidade é a variação do espaço em relação a variação do tempo, a aceleração é a variação da velocidade também em relação a variação do tempo, e pela propriedade referida por Peduzzi e Peduzzi (2006), a aceleração também é uma grandeza vetorial. É graças a aceleração que a velocidade aumenta em relação ao seu sentido (aceleração no mesmo sentido), diminui (aceleração no sentido oposto) ou se mantém constante (aceleração igual a zero). Foi convencionado neste trabalho tratar a velocidade em metros por segundo (m/s) e, por consequência, a aceleração foi medida e analisada em metros por segundo ao quadrado (m/s^2).

Uma das grandezas mais conhecidas e atuantes no nosso planeta é a aceleração da gravidade. Toda matéria presente na superfície do nosso planeta está sujeita a uma aceleração constante de aproximadamente $9,8m/s^2$ em direção ao centro da Terra. Vamos retomar à ideia de referencial e considerar que nossa posição atual é a região central do planeta, de forma que o sentido do vetor gravidade \vec{g} forma um ângulo reto (90°) em relação ao solo. Ao pegarmos um peso livre para realizar um exercício qualquer, existirão dois momentos de execução que variam de acordo com o exercício: o indivíduo aplica uma força no peso livre para colocá-lo em movimento contra a força da gravidade, gerando uma força de impulso (\vec{v}_i); em outro momento

o indivíduo atua com a inércia em relação à gravidade, não aplicando uma força direta nem contra, nem a favor da gravidade, mas sim oferecendo resistência ao seu efeito (\vec{v}_r) – exemplificado pela Figura 2.1.

Figura 2.1 – Representação do movimento de impulso e resistência



Fonte: Do autor (2023).

A geração dessas forças está presente na contração muscular (ARAUJO, 2022, p. 10).
Dividindo um exercício em três fases:

- fase **concêntrica**, onde há o encurtamento das fibras musculares ou ângulos articulares em decorrência da aproximação da origem e inserção do músculo;
- fase **excêntrica**, onde há o alongamento das fibras musculares ou ângulo articulares em decorrência do afastamento da origem e inserção do músculo;
- fase **isométrica**, onde há a geração de uma tensão sobre as fibras musculares, porém sem o afastamento ou alongamento da origem e da inserção do músculo.

A fase isométrica é mais comum em exercícios em que o indivíduo deve ficar parado em uma posição que gere essa tensão muscular, como na prancha abdominal e no agachamento estático, nesta modalidade as repetições são substituídas por medidas temporais – esta pesquisa não contempla esse tipo de exercício. Já as fases concêntrica e excêntrica compõem os exercícios dinâmicos que são executados por um determinado número de séries e repetições – é o foco desta pesquisa. Uma série é um conjunto de repetições do mesmo exercício intercaladas por um descanso específico, ao passo que uma repetição é o intervalo de tempo que compreende a passagem de uma fase para a outra do exercício. Assim, a realização de três séries de quinze repetições de um exercício implica que o usuário irá realizar quinze passagens de fase do exercício, descansar, realizar mais quinze, descansar de novo e repetir as últimas quinze repetições.

2.2 Corpo e movimento

O corpo humano tem sido objeto de estudo e admiração desde tempos anteriores aos da construção dos primeiros ginásios. Existem escritos sobre métodos de tratamento de doenças e reestabelecimento da saúde feitos nas antigas civilizações egípcias, indianas e chinesas, demonstrando que o funcionamento do corpo humano já era pesquisado nessas eras, vindo a formar um campo importante da biologia denominado **fisiologia**. Descrita por Silverthorn (2017) como sendo o estudo do funcionamento normal de um organismo e de suas partes, a fisiologia é uma área do conhecimento cujos conceitos são importantes para este trabalho, principalmente em razão do entendimento dos sistemas fisiológicos – em especial o sistema musculoesquelético responsável pela sustentação do corpo e pelo movimento – e sua integração ao referencial abordado.

A capacidade que o corpo humano possui de praticar exercícios é extremamente adaptável e melhorada com uma rotina bem elaborada, sendo uma propriedade fundamental para o desenvolvimento de novas áreas de fisiologia voltadas para o corpo em movimento, como a **fisiologia do exercício** e a **fisiologia do esporte** (KENNEY; WILMORE; COSTILL, 2020). Embora pareçam similares, a fisiologia do exercício implica no estudo das funcionalidades do corpo em um estado fisicamente ativo, enquanto que a fisiologia do esporte concentra-se no aprimoramento do treinamento de atletas e do seu desempenho esportivo.

Além do conhecimento sobre o funcionamento do corpo humano durante a prática de atividades físicas, outra área importante a ser considerada neste trabalho é a **cinesiologia**: o estudo do movimento sob o ponto de vista físico com o objetivo de entender as forças que atuam sobre ele (PORTELA, 2016). O movimento é uma ação intrínseca na atividade física e define a funcionalidade de um exercício, já a sua correta execução é que definirá sua eficiência. São exemplos de movimentos fundamentais: abdução e adução; flexão e extensão; rotação medial e lateral; pronação e supinação. Esses movimentos aplicados nos exercícios físicos trabalham grupos musculares de diversas maneiras a depender de variáveis como a força exercida e a estrutura geradora do movimento.

A mecânica é a ciência que tem por objeto o estudo das forças ou da sua ação, também é a combinação de itens com o objetivo de transmitir movimento. Os princípios da mecânica aplicados no estudo de aspectos anatômicos e funcionais de seres vivos define a biomecânica (HALL, 2013). Aplicada ao movimento humano, a biomecânica configura um campo da cinesiologia voltado para a análise de forças, principalmente as que são produzidas pelos músculos

(força interna) e as que atuam sobre o corpo (força externa). É a biomecânica que indica as formas seguras de execução de exercícios, principalmente os que envolvem levantamento de pesos. Também é a área do conhecimento que confere análises qualitativas do exercício físico e entendimento das interações de forças que o envolvem.

Assim, a fisiologia do exercício define as propriedades que devem ser analisadas para avaliação da eficácia de um determinado exercício que tem sido praticado durante um período bem definido por um usuário específico, provendo as informações necessárias para geração de *feedback* a esse usuário sobre a eficácia da inclusão deste exercício em seu treinamento. A análise cinesiológica dos movimentos que estão sendo executados pelo usuário confere meios de identificar o exercício e a contagem das séries e repetições. Já a biomecânica possibilita avaliar as forças atuantes e a análise da execução do exercício de modo a informar o usuário sobre movimentos que podem ser prejudiciais a sua saúde se estiverem sendo executados de forma incorreta.

2.3 Internet das coisas

Ao imbuir pesos livres com sensores capazes de medir as forças ligadas a sua movimentação, é possível analisar os movimentos que estão sendo executados. Essas medições, combinadas a um histórico de dados, possibilita identificar que tipo de exercício está sendo executado, quantas repetições estão sendo feitas, quanto tempo de descanso está sendo tomado e quantas séries foram totalizadas, permitindo ao usuário dedicar seu foco à execução correta da atividade. Essas informações devem ficar acessíveis para o treinador para que sejam analisadas assincronamente, melhorando o acompanhamento da evolução dos praticantes de musculação, tornando mais eficiente o acompanhamento local de usuários e possibilitando treinos remotos eficientes como uma alternativa para tempos de crise de saúde ou para pessoas que possuem pouco tempo disponível para lidar com uma rotina de frequência nas academias.

Essa estruturação inteligente faz parte de um conceito tecnológico em grande crescimento nos últimos anos: a Internet das Coisas (*Internet of Things* – IoT), um conjunto de tecnologias e protocolos associados que permitem que objetos se conectem a uma rede de comunicações que os identifique e os controle (CAVALLI; MEINERS, 2016). Para Goyal et al. (2020), a IoT representa o futuro das computações e comunicações tecnológicas devido à grande conectividade que essa tecnologia fornece para vários tipos de dispositivos e objetos, de forma automatizada, i. e. sem a necessidade direta de intervenção humana. É comum que aplicações

de IoT sejam baseadas em nós sensores, dispositivos que são capazes de converter parâmetros do ambiente (e. g. temperatura, umidade, luminosidade) em sinais elétricos (KASSAB; DARABKH, 2020). Esses sensores são gerenciados por microcontroladores e a comunicação pode ser feita por meio de módulos de rede como Wi-Fi, Bluetooth, ZigBee, 3G, 4G, 5G e sinal infravermelho.

De acordo com uma revisão sistemática realizada por Wang et al. (2021) sobre a evolução da IoT, as primeiras literaturas que utilizaram essa terminologia surgiram em 2002. Desta época para cá, essa tecnologia tem recebido investimentos de instituições governamentais e corporações por vir tendo se mostrando uma tecnologia importante, capaz de gerar impactos muito positivos na qualidade de vida e de ambientação da sociedade atual. Os nós sensores fornecem aos objetos mais variados, aos quais são integrados, habilidades de reconhecer parâmetros do ambiente e de comunicar-se em rede. A internet das coisas tem expandido horizontes do quesito comunicação tecnológica, cunhando um contexto de **hiperconectividade**, conceito que descreve o estado de disponibilidade dos indivíduos para se comunicarem a todo instante. No livro de Magrani (2018, p. 21), os autores citam alguns desdobramentos dessa disponibilidade como:

- a) *always-on*, onde indivíduos estão conectados durante todo o tempo;
- b) *readily accessible*, quando há a possibilidade de estar prontamente acessível;
- c) *always recording*, referindo-se à riqueza de informações, à interatividade e ao armazenamento ininterrupto de dados;
- d) *person-to-person*, comunicação entre pessoa e pessoa;
- e) *human-to-machine*, comunicação entre pessoa e máquina;
- f) *machine-to-machine*, comunicação entre máquina e máquina.

Atualmente, por exemplo, lâmpadas com sensores de detecção de presença se acendem automaticamente quando pessoas adentram determinado recinto; postes de iluminação pública se acendem automaticamente quando detectam diminuição da luminosidade do dia identificando o início do período noturno e se apagam quando detectam aumento da luminosidade natural com o início do período vespertino; estufas estabelecem um período de rega baseado em informações sobre a umidade do solo; focos de incêndio são rapidamente identificados e combatidos em áreas de risco devido a leituras de sensores de pressão, fumaça e temperatura; veículos identificam limites de estacionamento com sensores de proximidade; telefones identificam a rotação da tela por meio de sensores de velocidade angular; sistemas de saúde com

nós vestíveis se comunicam com clínicas aferindo dados fisiológicos do usuário como pressão arterial, glicemia e frequência cardíaca; indústrias de moda aliadas a integrações com a saúde utilizam tecnologias vestíveis para acompanhar a temperatura do corpo por meio de sinais que alteram a cor na vestimenta alertando sobre alterações fisiológicas (Figura 2.2); e, tema desta pesquisa, movimentações são reconhecidas por meio de sensores inerciais.

Por outro lado, um grande número de dispositivos conectados acompanhando rotinas dos mais variados âmbitos da vida humana (*e. g.* sociedade, família, relacionamentos, intimidade e saúde), coletando, armazenando e compartilhando quantidades massivas de dados, muitas vezes pessoais e estritamente confidenciais, levanta preocupações pertinentes no desenvolvimento e evolução desta tecnologia devido aos riscos que ela pode acarretar para a privacidade e a segurança dos usuários (MAGRANI, 2018). Por isso, é boa prática o uso de redes locais internas para comunicação de dados, aplicação de chaves de segurança, criptografia, protocolos e certificados para reconhecimento e estabelecimento de comunicações com pontos de acesso seguros, evitar tráfego de dados sensíveis e, quando necessário estabelecer conexão com a rede global, utilizar medidas de proteção como firewalls e VPNs (*Virtual Private Network*). Também é importante verificar as condições dos sensores em relação ao mau funcionamento, desgastes e manutenções necessárias.

Figura 2.2 – Protótipo de tecnologia vestível que identifica temperatura corporal



Fonte: Wakita et al. (2005).

2.3.1 Sensores inerciais e microcontroladores

Compostos por sensores de aceleração linear (acelerômetros) e sensores de velocidade angular (giroscópios), os sensores inerciais têm se tornado muito comuns nos últimos anos a um preço consideravelmente baixo. Os *smartphones*, por exemplo, possuem vários desses sensores em sua arquitetura (BENSER, 2015). Inclusive, como apontado por Lara e Labrador (2013), acelerômetros possuem baixo custo energético e vêm apresentando alta precisão de reconhecimento sob diferentes metodologias de avaliação. A nomenclatura “inercial” se refere ao fato de que esses sensores seguem o princípio de inércia e portanto medem seu próprio movimento – ou o movimento do objeto ao qual estão acoplados. Este trabalho propôs acoplar sensores inerciais em pesos livres para analisar os movimentos aplicados sobre eles.

Avanços recentes na tecnologia têm tornado esses sensores cada vez menores e com capacidade para alinhar mutualmente três acelerômetros e três giroscópios de forma ortogonal. Esse tipo de configuração, segundo Iosa et al. (2016, p.625), é geralmente referenciada como sendo uma Unidade de Medição Inercial (IMU – *Inertial Measurement Unit*). Assim, uma IMU realiza uma medição tridimensional da aceleração linear e velocidade angular do sensor ou objeto/sistema ao qual ele se encontra acoplado. Todavia, a precisão dessa medição é altamente dependente da qualidade dos sensores e dos erros inerentes a eles, sendo necessário um processo de calibração que compreende o reconhecimento e correção desses erros (PODDAR; KUMAR; KUMAR, 2016).

Para os erros comumente encontrados em sensores inerciais, Poddar, Kumar e Kumar (2016) classificam-lhes em determinísticos e aleatórios. Os erros determinísticos são aqueles que podem ser identificados pela saída do sistema e estão presentes devido a erros de manufatura do equipamento. São exemplos de erros determinísticos a saída diferente de zero produzida pelo sensor quando nenhuma entrada é exercida ou fornecida sobre ele, comportamento da saída em relação a modificações na entrada e desalinhamento de leitura devido a defeitos de fábricas. Já os erros aleatórios estão ligados à flutuação de resposta do sistema, se comportando de forma não predizível. Um exemplo de erro aleatório é o sistema estar programado para fazer n leituras por segundo, mas em alguns momentos realiza m leituras, onde $n \neq m$.

A correção de erros em sensores inerciais é fundamental logo na fase inicial de medição uma vez que serão reverberados para todo o processo. Os erros aleatórios requerem investigação mais aprofundada de suas ocorrências, uma vez que não podem ser previstos, contudo, os erros determinísticos podem ser corrigidos ou bem amenizados com base em técnicas de calibragem.

No trabalho realizado por Morton, Baillie e Ramirez-Iniguez (2013) são abordadas algumas dessas técnicas, em especial as chamadas técnicas de posição (*pose*) que consistem em posicionar o sensor de forma que se conheçam os valores esperados de saída e então compará-los com os valores reais que estão sendo lidos. A partir dessa comparação são obtidos os chamados valores de desvio ou *offsets* cuja aplicação torna o sensor em questão calibrado.

Um microprocessador é um processador compacto sem periféricos, próprio para execução de funções lógicas e aritméticas definidas por um programa. Um microcontrolador, por sua vez, consiste em um circuito integrado altamente compacto capaz de realizar determinadas tarefas de maneira eficaz (IEEE RAS UFCG, 2020). Inicialmente dedicados a interfaces de entrada e saída, os microcontroladores surgiram em 1974 com a comercialização do Intel 8048 (o primeiro microcontrolador comercializado) e passaram por uma popularização em meados dos anos 80 onde, a partir dessa época até os dias atuais, receberam incrementos como memória RAM e EPROM, circuito de oscilador, interfaces de comunicação serial e USB e, por fim, interfaces de rede, Ethernet, Wi-Fi e Bluetooth, culminando na internet das coisas conhecida nos dias de hoje (OLIVEIRA, 2017; ZURITA, 2011). Este recurso tem sido utilizado em uma ampla variedade de aplicações, envolvendo indústrias automotivas, eletrodomésticos, equipamentos industriais e dispositivos de consumo geral.

2.4 Análise do movimento e algoritmos de classificação

A análise de movimentos é capaz de fornecer parâmetros cinéticos e cinemáticos⁴ que auxiliam no reconhecimento dos movimentos em execução, tendo sido empregada inclusive em avaliações clínicas, reabilitações, esportes e no auxílio de diagnósticos (IOSA et al., 2016, p. 642). Essa análise pode ser feita de diversas formas, a depender do objetivo final e recursos disponíveis.

É possível analisar o movimento de indivíduos saudáveis para desenho técnico de soluções que auxiliem na reabilitação de pacientes com movimentos debilitados. Uma implementação desse tipo foi feita por Desplenter et al. (2016), onde sensores inerciais foram acoplados ao pulso e braço de um indivíduo saudável para analisar a movimentação da articulação do cotovelo (Figura 2.3, b), os dados coletados então foram utilizados para prototipação de um sistema vestível que auxiliasse na reabilitação de pacientes com esse tipo de movimento em específico prejudicado (Figura 2.3, a).

⁴A cinética é o estudo das forças que causam um movimento, enquanto que a cinemática é o estudo do movimento em si.

Outro método de análise de movimentos dá-se por meio de câmeras especializadas no reconhecimento dos movimentos cinéticos e cinemáticos das articulações do corpo humano, porém, como apontam Iosa et al. (2016, p. 642) e Mota (2017, p. 31-32), esse método é pouco acessível devido ao seu alto custo e ambientação. Os autores também apontam o surgimento de tecnologias mais acessíveis, discretas e menos invasivas como os sensores inerciais discutidos na seção 2.3.1.

Figura 2.3 – Sistema vestível para reabilitação da articulação dos cotovelos



Fonte: Desplenter et al. (2016).

O uso desses sensores como uma alternativa ubíqua, de baixo custo e de ampla aplicação tem sido empregado em diversas pesquisas nas últimas décadas. No fim dos anos 80, Baron e Plamondon (1989) desenvolveram um sistema baseado em acelerômetros para analisar o movimento produzido durante uma assinatura manual realizada por meio de uma caneta sensorizada conhecida como *accelerometer pen*, dotada de dois pares de acelerômetros em seu interior, um par em cada extremidade. Da escrita à movimentação de braço, Harrington, Daniel e Kyberd (1995) propuseram um sistema de reconhecimento de gestos com o braço por meio da medição realizada por acelerômetros, incluindo rotações. Os sensores foram fixados por meio de uma barra de metal atada ao braço e antebraço do indivíduo.

Com o avanço da tecnologia, novas possibilidades foram surgindo e possibilitando avaliações mais complexas, precisas e flexíveis. Um sistema computacional baseado em Redes de Sensores Sem Fio (RSSFs) foi proposto por Mota (2017) para análise biomecânica da marcha humana. Os nós sensores utilizados foram compostos de um microcontrolador ESP8266 com módulo Wi-Fi conectado a um módulo inercial MPU-6050 que funciona com seis eixos, os nós foram fixados aos membros inferiores dos indivíduos. Por meio de um único acelerômetro acoplado a um relógio de pulso, Silva e Galeazzo (2013) desenvolveram um sistema capaz de

reconhecer movimentos simples do dia-a-dia de um ser humano, como estar: deitado, sentado, de pé, andando, correndo, deslocando-se em escadas e trabalhando no computador.

O reconhecimento de movimentos não limita seu alvo de estudo apenas aos humanos. O trabalho de Chakravarty et al. (2019) cita diversas pesquisas baseadas na inferência do comportamento de animais utilizando dados puros vindos de acelerômetros. Além disso, os autores propuseram um *framework* de reconhecimento de comportamento animal baseado em um modelo híbrido que combina movimentos biomecânicos com uma arquitetura inteligente de árvore hierárquica. Dessa forma, é possível observar que o sensoriamento é parte fundamental de um sistema de reconhecimento de movimentos e que a internet das coisas, por consequência, se torna um objeto de estudo muito viável e importante para essa área de pesquisa, reduzindo custos, aprimorando recursos e otimizando resultados.

A maioria dos trabalhos destacados nessa seção tiveram como fim uma tecnologia vestível (CHAKRAVARTY et al., 2019; IOSA et al., 2016; MOTA, 2017; SILVA; GALEAZZO, 2013). Os dispositivos que compõe essa tecnologia são chamados de *wearables* e, segundo Vishkaie (2018, p. 443, grifo nosso): “[...] dizem respeito a uma classe grande de dispositivos que incluem aparelhos de se usar no pulso (como *smarthwatches* e *trackers*⁵); itens usados em roupas, como tecidos eletrônicos (*e-textiles*⁶ – Figura 2.2) e adesivos; e *head mounted displays*⁷”. Ou seja, qualquer dispositivo que possa ser utilizado como uma roupa ou acessório com conectividade e/ou integração eletrônica. Já o trabalho de Baron e Plamondon (1989) se dedicou à avaliação de um objeto “não necessariamente vestível”⁸ (caneta) que possuía uma função específica: escrever.

Para o cenário de treinos dinâmicos, tecnologias vestíveis, embora muito utilizadas em ensaios e testes, podem transmitir uma sensação invasiva além de não oferecerem a praticidade que os treinos de musculação com pesos livres requer. Por conta disso, este trabalho analisou o uso de sensores inerciais vestíveis para explorar seus recursos e possibilidades, e então voltou-se para o cenário de sensoriamento de acessórios externos para que contemplasse os pesos livres. Durante a revisão sistemática foram examinados trabalhos relacionados com aplicações de internet das coisas e sensoriamentos de cargas para monitorar e reconhecer exercícios,

⁵Dispositivos de rastreamento (GPS) ou de cronometragem para atividades físicas.

⁶Tecidos ou roupas que integram circuitos e componentes eletrônicos (HAMDAN; VOELKER; BORCHERS, 2018)

⁷Dispositivos moldados para serem usados na cabeça, semelhantes a capacetes, com monitores de imagem com foco na região dos olhos (SHIBATA, 2002). Comumente utilizados nas áreas de realidade virtual e aumentada.

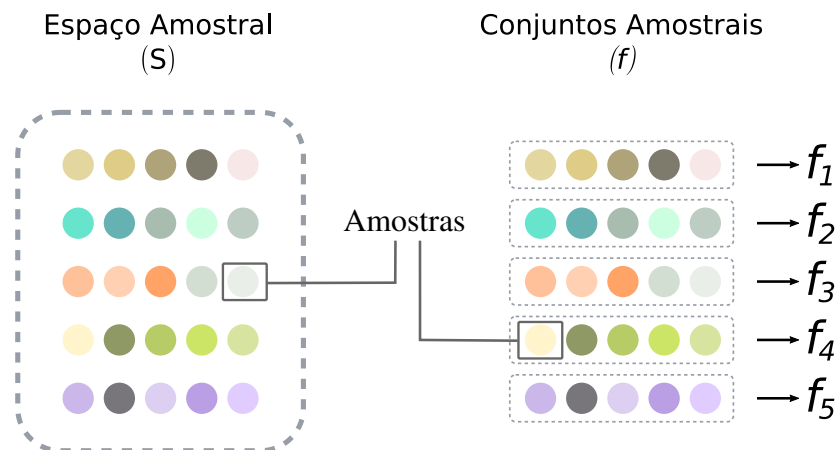
⁸Objetos que podem ser utilizados de forma vestível ou não. Que compõe uma vestimenta – muitas vezes como acessório – e que também são de uso externo e específico.

movimentos humanos, variáveis fisiológicas e atividades que ressoassem com a proposta desta pesquisa, trabalhos estes que serão apresentados e discutidos na seção 3.

2.4.1 Aprendizado de máquina e *scikit-learn*

Uma das ferramentas mais valiosas para a internet das coisas é o *Machine Learning* (ML) ou Aprendizado de Máquina. Como o nome supõe, essa ferramenta é uma área da inteligência artificial concentrada no desenvolvimento de algoritmos que possibilitam que máquinas aprendam organicamente, isto é, sem serem diretamente programadas (CHARBUTY; ABDULAZEEZ, 2021). Para isso, os algoritmos são alimentados por dados (amostras) com o objetivo de construir sistemas com a capacidade de implementar funcionalidades complexas como classificação, previsão e detecção de padrões. Em seguida é aplicada uma lógica de preparação dos dados deste espaço em grupos que compartilham alguma semelhança como valor, posição e/ou qualidade. Este espaço macro é chamado de espaço amostral (S) e os agrupamentos são chamados de conjuntos amostrais ou *features* (f), como exemplifica a figura 2.4.

Figura 2.4 – Espaço amostral e conjuntos amostrais



Fonte: Do autor (2023).

O monitoramento e, principalmente, a classificação de movimentos humanos é uma área de pesquisa muito importante dos campos de saúde, esporte e reabilitação e os algoritmos de ML desempenham um papel crucial na precisão e reconhecimento dessas classificações. A seguir, serão apresentados a linguagem de programação, bibliotecas e os algoritmos que foram utilizados na classificação dos dados colhidos neste trabalho, elencados com base em seus históricos de uso e bons resultados relacionados à área como indicado por Pedregosa et al.

(2011), Silva e Galeazzo (2013) e Erdaş et al. (2016).

Uma das linguagens de programação mais populares para a computação científica nos anos de 2011 foi a linguagem *Python*, em razão de sua natureza interativa, seu ecossistema maduro de bibliotecas científicas, e por ser uma escolha atraente para o desenvolvimento de algoritmos e exploração de análises de dados (MILMANN; AVAIZIS, 2011). Sua popularidade continuou em crescimento, sendo eleita a "Linguagem de Programação do Ano" em 2007, 2010, 2018, 2020 e 2021 pelo *TIOBE Programming Community Index* (TIOBE, 2023), um importante indicador de popularidade de linguagens de programação.

Devido a sua popularidade e eficiência na análise de dados, a linguagem *Python* foi adotada para o desenvolvimento de bibliotecas de aprendizado de máquina como a *scikit-learn*, criada em 2007 com o objetivo de fornecer implementações a nível de estado-da-arte de diversos algoritmos de ML conhecidos (PEDREGOSA et al., 2011). Essa biblioteca fornece suporte para aprendizados supervisionados, onde os dados são rotulados para que haja uma resposta na qual a máquina possa avaliar sua precisão, e não-supervisionados, onde os dados não possuem nenhuma rotulação fazendo com que a máquina deva entendê-los por conta própria. Cada algoritmo e módulo de ML suportado pela *scikit-learn* recebe o nome de *estimator* e podem ser ajustados para um conjunto de dados por meio do método *fit*. Após o ajuste ou fase de treino, o método *predict* pode ser chamado recebendo um conjunto de dados de teste para ser avaliado e ter um resultado de previsão (SCIKIT LEARN, 2023b).

O algoritmo 2.1 apresenta um exemplo conceitual de uso da *scikit-learn*. Uma variável nomeada de classificador recebe um objeto *estimator* montado a partir de atributos de configuração representados pelo parâmetro *param_figs*. Após a montagem, a variável invoca o método *fit* passando um par de parâmetros que correspondem a uma matriz de treino T e uma lista de resultados R . Cada linha i da matriz T representa um conjunto agrupado de amostras (f) do espaço amostral (S) coletado, e cada item j da lista R corresponde ao resultado esperado da linha correspondente em T (R_j é o resultado esperado da amostra T_i , se $i = j$). Por fim, passado o treinamento a variável classificador invoca o método *predict* para predizer os resultados da matriz P .

Percebe-se que as linhas da matriz P representam o mesmo conjunto amostral ($[1, 2, 3]$) e que esse conjunto faz parte do conjunto de treino T cujo resultado esperado é 0. Sendo assim, o método *predict* irá retornar uma lista $[0, 0]$ pois está predizendo conjuntos que fizeram parte do seu treinamento. Essa representação foi proposital para demonstrar o funcionamento

Algoritmo 2.1 - Exemplo do uso de um *estimator* e método *fit* com a *scikit-learn*

Entrada:

Matriz T de conjunto de treino (e. g.: $[[1, 2, 3], [11, 12, 13]]$);

Matriz P do conjunto de dados a ser predito (e. g.: $[[1, 2, 3], [1, 2, 3]]$);

Lista R com o resultado de cada conjunto de treino (e. g. $[0, 1]$).

Saída:

Lista com os resultados da predição de P em relação aos dados treinados de T com resultado R .

```

1 início
2   | classificador ← estimator(param_config);
3   | classificador.fit( $T, R$ );
4   | classificador.predict( $P$ );
5 fim
```

da biblioteca. Em um cenário real, no entanto, a matriz P seria formada majoritariamente por conjuntos semelhantes aos de T , para compartilharem um mesmo desfecho, mas não idênticos – a medida que o espaço amostral cresce, os conjuntos amostrais ficam mais complexos e os dados ficam mais voláteis, a possibilidade de existirem dois conjuntos idênticos é mínima.

2.4.2 *Decision Tree (DT)*

A todo momento o reino animal está tomando decisões, seja por puro instinto – como no caso dos animais irracionais – ou por instinto e aplicação de alguma lógica – caso dos seres humanos. Quando um predador está a espreitar uma presa, ele toma essa decisão baseado em oportunidade e fome, em conjunto com variáveis históricas que inconscientemente o ensinaram que tipo de presa pode ser caçada, que a taxa de sucesso aumenta se ele não for percebido precocemente pelo alvo e fatores de território. Por outro lado, quando uma presa corre o risco de ser predada, ela toma a decisão de fuga ou luta baseado em fatores como tamanho do predador, se está só ou em bando e sinais sonoros que indicam presença de perigo.

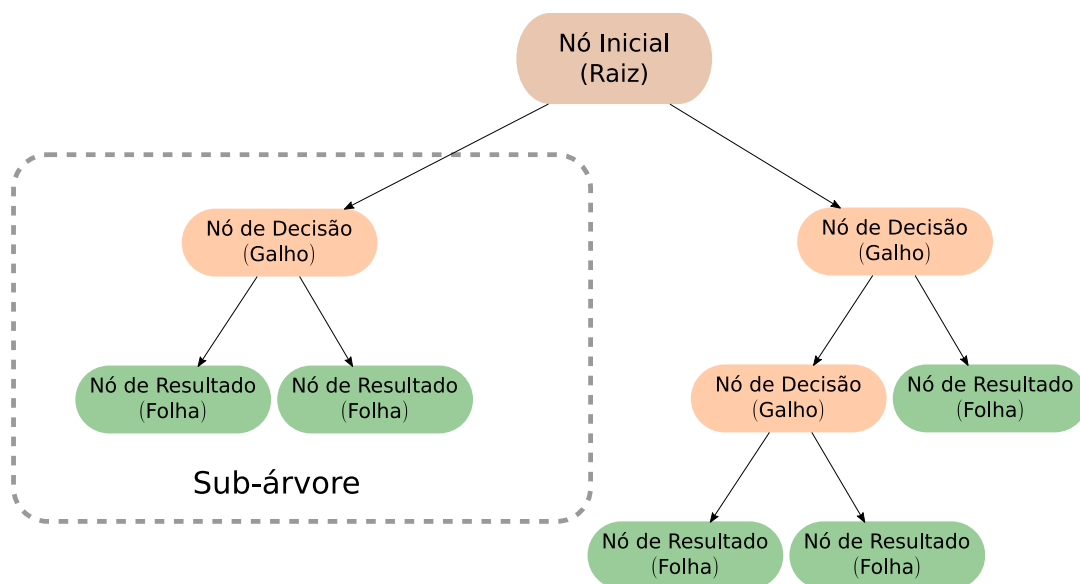
Quando vamos decidir que roupa usar para algum evento, levamos em consideração diversos fatores como o clima (chuvoso ou ensolarado), a temperatura (quente ou frio), a dinâmica social (formal ou informal), o ambiente (cidade ou campo), o objetivo (dançar, correr ou nadar), e por assim vai se estendendo nossa lista de considerações a depender do caso. Mediante esta observação, percebe-se que esse modo de decisão está relacionado a um determinado conjunto de variáveis que produzem um específico conjunto de resultados.

Esse mecanismo de avaliar os fatores para tomar uma decisão referente a uma predição

é o núcleo de funcionamento dos algoritmos baseados em árvores de decisão. Uma revisão geral do uso desta técnica com aplicações em aprendizado de máquina foi realizado por Navada et al. (2011) onde, segundo os autores, uma árvore de decisão utiliza um grafo de decisões em formato de árvore – com raízes, galhos e folhas – para prever resultados como: gasto de recursos, desenlace de eventos e utilitarismos; também verificaram que os algoritmos foram se atualizando conforme a necessidade de uso, resultando em variações, como: árvores de classificação, árvores de regressão, florestas de árvores de decisão e aglomerações de K meios (*K Means Clustering*); usadas respectivamente em: probabilidade e estatística, cálculos de estado real, resultados particularmente complexos e retroalimentação e expansão de resultados pontuais para validação do meio.

Em sua estrutura, o grafo da árvore de decisão possui três tipos de vértices que são chamados de nós: inicial, de decisão e de resultado (Figura 2.5). Levando em consideração a analogia com uma estrutura de árvore, pode-se interpretar o nó inicial como sendo a raiz da árvore, o nó de decisão como sendo o galho de intermediação e o nó de resultado como sendo a folha da árvore, seu ponto final. Além disso, ao se analisar micro-espacos dentro da árvore é possível observar a existência de sub-árvores geradas por meio da transformação de um nó de decisão em um nó inicial.

Figura 2.5 – Estrutura de uma árvore de decisão



Fonte: Adaptado de Charbuty e Abdulazeez (2021).

Algumas vantagens significativas de algoritmos de árvores de decisão são: sua estrutura

pode ser visualizada, o que auxilia no seu entendimento e interpretação; desde que haja o que ser decidido, os algoritmos podem ser treinados com conjuntos pequenos sem problemas, exigindo pouca preparação em relação a outros algoritmos de ML; o custo computacional ligado à predição de dados é de ordem logarítmica (baseado nos pontos de dados usados para treinar a árvore); como a árvore pode se guiar em direção a diversos nós folhas, problemas de decisão que requerem múltiplas opções de resultado são bem tratados com esse módulo; pode ser validada com modelos de teste estatísticos, o que tem grande peso para a confiabilidade da solução; a sua performance é relativamente boa mesmo quando há desvios nos dados que poderiam comprometer outros métodos.

Em contrapartida, essa classe de algoritmos têm suas desvantagens, como: a árvore pode ficar muito complexa se o treinamento não for bem feito; pequenas variações nas amostras podem mudar toda a estrutura da árvore; as predições são orientadas de forma pontual a cada nó de decisão e isso pode causar desvios do caminho ótimo; a utilização de técnicas de algoritmos gulosos levam a árvore a buscar a melhor solução local e não global; alguns conceitos lógicos são difíceis de serem aprendidos pela técnica. Além dos pontos apresentados, é preciso muito atenção para a configuração da amostragem, pois árvores treinadas com conjuntos amostrais muito dominantes em relação aos outros podem torná-la tendenciosa. O quadro 2.1 apresenta uma síntese das vantagens e desvantagens dos algoritmos de árvores de decisão.

2.4.3 *Multi-layer Perceptron (MLP)*

As redes neurais artificiais (RNAs) são sistemas computacionais inspirados no funcionamento do sistema nervoso humano e na sua estrutura. Em 1957, o nome Perceptron foi proposto pelo psicólogo Frank Rosenblatt como uma classe de RNA, incorporando aspectos de comunicação cerebral e receptores biológicos de forma artificial (KANAL, 2003). O cérebro humano consiste em bilhões de células individuais chamadas de neurônios de forma que a quantidade e a natureza das conexões entre elas é praticamente impossível de conceber (NORIEGA, 2005). A nível computacional, todavia, os neurônios como conhecemos podem ser modelados como dispositivos simples de entrada e saída de dados conectados em uma rede onde as conexões são conhecidas como sinapses.

Dentre as topologias de uma RNA, o Perceptron Multicamadas (MLP – *Multi-layer Perceptron*) possui natureza supervisionada e potencial reconhecido na classificação de padrões e exercícios físicos são baseados em repetição de movimentos, o que propicia o surgimento de padrões cuja identificação leva à classificação do exercício propriamente dito. Essa técnica leva

Quadro 2.1 – Vantagens e desvantagens das árvores de decisão


Vantagens	Desvantagens
Simplicidade de implementação	Supercomplexização de generalizações
Possibilita treinamentos pequenos	Instabilidade por pequenas variações
Tem custo computacional logarítmico	Predições variantes
Lida com dados numéricos e categóricos	Dificuldades no aprendizado ótimo
Funciona com problemas de múltiplas saídas	Cenários difíceis de aprender
Validação estatística	Tendências dirigidas

Fonte: Adaptado de Scikit Learn (2023a).

o nome de multicamadas pois funciona com no mínimo três camadas, sendo uma de entrada, uma escondida e uma de saída (Figura 2.6), cada qual formada por um conjunto de neurônios com a responsabilidade de tratar os dados e enviar para a camada seguinte através de suas sinapses, onde cada sinapse recebe um peso que determina a sua importância na transmissão da informação (FANUCCHI; OLESKOVICZ; BARBOSA, 2013).

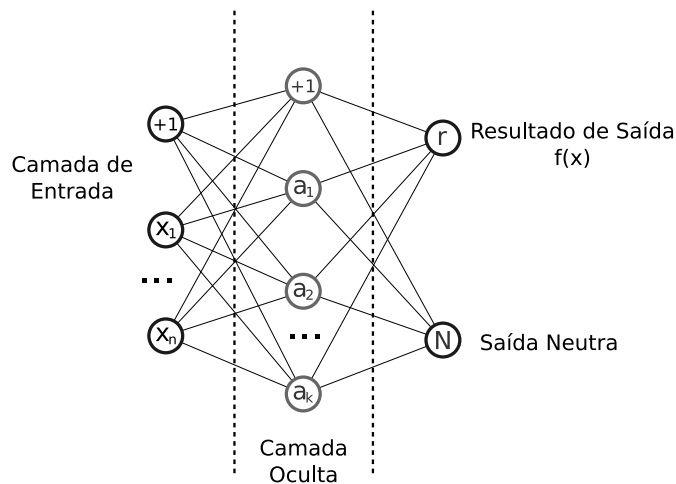
O algoritmo deve aprender uma função $f(\cdot) : R^m \rightarrow R^o$ por meio do treinamento dos conjuntos amostrais, onde m é o número de dimensões por entrada e o é o número de dimensões de saída. Acompanhando a figura 2.7 é possível observar que a camada de entrada é formada por uma série de neurônios $\{x_i | x_1, x_2, \dots, x_m\}$ que representam as *features*. A camada oculta recebe os valores da camada de entrada transformando-os com uma sumarização linear como $w_1x_1 + w_2x_2 + \dots + w_mx_m$, seguida de uma função de ativação não linear $g(\cdot) : R \rightarrow R$ (SCIKIT LEARN, 2023d). A camada de saída recebe os valores da camada oculta e os transforma em dados de resultado, com a opção de uma saída neutra representando um resultado padrão caso não haja saídas compatíveis com o resultado da classificação.

Figura 2.6 – Arquitetura de MLP com duas camadas ocultas



Fonte: Adaptado de Falcão et al. (2013).

Figura 2.7 – MLP de camada oculta única, *features* e saída neutra



Fonte: Adaptado de Scikit Learn (2023d).

A principal vantagem das redes neurais artificiais está na sua capacidade de aprendizado alimentado com exemplos de treinamento dos mais diversos como fotos, textos, funções, dados binários e números, encontrando soluções cujo caminho passaria despercebido por um raciocínio orgânico. Além disso, uma RNA aprende conforme é utilizada, melhorando-se continuamente sem perder o processo de treinamento intensivo na qual foi desenvolvida, isto lhe confere a qualidade de ser tolerante a falhas e ao mesmo tempo de se adaptar a mudanças necessárias.

Entretanto, as fases que passam pelas camadas ocultas conferem aos algoritmos de RNA uma indagação de como ela chegou aos resultados da camada de saída, o que dificulta muito o procedimento de depuração dessas técnicas e torna mais complexo o desenvolvimento de solu-

ções baseadas nessa tecnologia. As redes neurais também possuem a característica de decidirem probabilisticamente, i. e. elas não chegam a um veredito, mas sim a uma escolha baseada na maior probabilidade calculada. Em geral, as RNAs requerem muito mais dados para seu aprendizado do que outros algoritmos de aprendizado de máquina, o que se torna um problema em objetivos que demandam dados muito singulares ou de difícil coleta, com isso o custo computacional se eleva, principalmente se a rede depender de muitas camadas ocultas para chegar aos seus resultados. O quadro 2.2 apresenta uma listagem de vantagens e desvantagens relacionadas às RNAs.

Quadro 2.2 – Vantagens e desvantagens das RNAs

Vantagens	Desvantagens
Auto-aprendizagem	Ação oculta
Filtragem de ruído eficiente	Natureza probabilística das respostas
Adaptabilidade a mudanças	Desenvolvimento
Tolerância a falhas	Qualidade dos dados
Velocidade de trabalho	Custo computacional

Fonte: Adaptado de Safonov (2022).

2.4.4 *K Nearest Neighbours (kNN)*

Sendo um dos conjuntos de algoritmos mais intuitivos de aprendizado de máquina (XING; BEI, 2020), o kNN baseia-se em classificar uma amostra baseado nos vizinhos mais próximos dela (Figura 2.8). Esse ponto de vista de proximidade leva em consideração variáveis que estão sendo analisadas, como características, pesos, valores, categorias, e outros. O número de vizinhos que será escolhido para testar a classificação é definido pelo usuário por meio de uma constante k .

Considerando um plano bidimensional, um ponto é formado por duas coordenadas (x e y) e o cálculo de distância entre dois pontos nos algoritmos de kNN geralmente retorna medidas métricas, sendo muito utilizado os cálculos de distância Euclidiana (D_E) e distância Manhattan


(D_M). Nas equações 2.1 e 2.2 é possível ver o funcionamento desses cálculos considerando dois pontos (U e V).

$$D_E(U, V) = \sqrt{\sum_{i=1}^n (U_i - V_i)^2} \quad (2.1)$$

$$D_M(U, V) = |U_x - V_x| + |U_y - V_y| \quad (2.2)$$

Algoritmos baseados em vizinhos próximos são conhecidos como métodos de aprendizado de máquina não-generalizados, por memorizarem todos os dados de treinamento, performando estruturas de indexação rápida que fazem com que a classificação não se dê por um aprendizado instanciado de um modelo construído, mas sim por consultas ao dados de treino armazenados (SCIKIT LEARN, 2023c). Isso torna o algoritmo simples e prático, sendo utilizado com sucesso em problemas de classificação e regressão complexos como reconhecimento de números manuscritos, cenas de imagens de satélites e situações de decisão com limites irregulares. Porém, também traz lentidão no processamento de dados super categorizados, de grande tamanho ou com classes muito esparsas.

Figura 2.8 – Classificação em kNN de 3 classes com k igual a 5



Fonte: Adaptado de Raschka (2018).

Uma particularidade dessa classe de algoritmos de ML é a de estarem suscetíveis ao curso de dimensionalidade: cenários com um tamanho fixo de conjuntos amostrais de treina-

mento, mas com aumento no número de dimensões e faixa de valores de *features* em cada dimensão. Essa situação pode se tornar problemática porque quanto mais dimensões são adicionadas, mais volume de dados no hiperespaço será necessário para capturar um número fixo de vizinhos (RASCHKA, 2018). Algoritmos desse módulo precisam regular o conjunto amostral para que estejam na mesma escala de forma que o kNN possa calcular a distância entre vizinhos. No quadro 2.3 é possível observar uma lista de vantagens e desvantagens dos algoritmos baseados em kNN.

Quadro 2.3 – Vantagens e desvantagens dos kNNs

Vantagens	Desvantagens
Facilidade de implantação	Dificuldade com dimensões elevadas
Não requer treinamento	Algoritmo lento (<i>lazy</i>)
Espaço amostral adaptativo	Exige dados homogêneos
Resolve problemas de múltiplas classes	Mau funcionamento com dados desbalanceados

Fonte: Adaptado de Raschka (2018), Scikit Learn (2023c) e Xing e Bei (2020).

3 TRABALHOS RELACIONADOS

Com o avanço de estudos na área de internet das coisas, de face para suas vantagens e bons resultados, muito têm sido desenvolvido nos últimos anos. No entanto, aplicações de internet das coisas no cenário de atividades físicas tem sido relativamente pouco exploradas, a maioria das aplicações com esse foco visam automatizar o processo de contagem das séries e repetições, além de controlar o conjunto de exercícios e condições fisiológicas do usuário ou do ambiente. Muitos estudos sobre o reconhecimento de atividades humanas (HAR) também têm sido desenvolvidos, porém com foco em atividades específicas como corrida e ciclismo. O quadro 3.1 lista os principais trabalhos encontrados na revisão bibliográfica com um resumo das diferenças para o nosso trabalho. Os parágrafos subsequentes descrevem detalhadamente quais foram esses trabalhos e como eles estão relacionados ao nosso.

Quadro 3.1 – Comparação entre os trabalhos relacionados e o trabalho proposto.

Trabalho	Tipo	Ambiente	Equipamentos em Foco
Jain (2015)	Framework Conceitual	Academia	Maquinário de Academia
Bathia e Sood (2018)	Framework	Academia	Maquinário de Academia
Rabbi et al. (2018)	Assistente Virtual	Academia	Maquinário de Academia e equipamento de realidade virtual
Oliver e Flores-Mangas (2006)	Aplicação Integrada (<i>mobile</i> e sensores)	A critério do usuário	Dispositivo <i>mobile</i>
Karandikar et al. (2019)	Aplicação Integrada (<i>mobile</i> e sensores)	Academia	Maquinário de Academia
Mota (2017)	Rede de Sensores Sem Fio	Experimental	Nós sensores anexados ao corpo
Proposto	Aplicação Integrada (ponto de acesso e sensores)	A critério do usuário	Pesos livres

Fonte: Do autor (2023).

Um *framework* conceitual foi proposto por Jain (2015) para uma academia inteligente, onde as máquinas de exercícios físicos são capazes de gravar: os números de séries e repetições executadas pelo usuário, a força aplicada e o tempo decorrido. Além disso, para fins ocupacionais e controle de recursos mediante lotação, o *framework* também indica se uma máquina está sendo usada. Um histórico é mantido sobre todos os dados relacionados às execuções de exercícios físicos nessas máquinas inteligentes com o objetivo de utilizar esses dados na formulação de novas rotinas de exercícios, conforme a evolução do usuário. Um dispositivo chamado de *fitness device* age na interface de comunicação entre o usuário e o sistema, além de monitorar qualquer anormalidade no estado vital do usuário, e. g. pressão arterial, pulsação, etc. O *framework* aborda conceitos importantes para a proposta deste trabalho, como o histórico de informações e a análise de forças e eventos quantitativos relacionados aos exercícios. Porém, o sensoriamento proposto pelo *framework* de Jain (2015) é voltado para o maquinário de uma academia e o monitoramento fisiológico do usuário. O projeto proposto neste trabalho foi voltado para pesos livres sem restrição de ambiente, e não há monitoramento de questões fisiológicas como batimento cardíaco – todo o foco se dará na execução dos movimentos dos exercícios.

Outro *framework* é proposto por Bhatia e Sood (2018) com foco no monitoramento em tempo real de atributos de saúde durante sessões de atividades físicas, analisando-os e pre-dizendo vulnerabilidades em tempo real. O *framework* é composto por quatro fases: sensoriamento (captura dos dados dos sensores), classificação (separação dos dados), mineração (garantia de recuperação das informações necessárias em tempo hábil) e predição/visualização (análise dos dados em tempo real mediante cálculo probabilístico). A identificação dos usuários foi feita por meio de etiquetas RFID durante o início de cada sessão de exercícios. Os autores observaram que é essencial prover mecanismos de segurança a nível de rede e banco de dados, uma vez que os dados relacionados à saúde do usuário são confidenciais. O protocolo de quatro fases utilizado no *framework* é similar à proposta deste trabalho, no entanto, para um cenário remoto onde as atividades serão executadas individualmente, a identificação do usuário será automática, nenhum outro dispositivo precisará ser usado para realizar essa autenticação. O *framework* de Bhatia e Sood (2018) também não aprofunda suas análises sobre a execução dos exercícios e nenhum histórico sobre eles foi implementado, o foco foi inteiramente sobre o estado fisiológico do usuário a fim de prever situações de risco dentro do cenário de uma academia.

JARVIS é um assistente virtual desenvolvido por Rabbi et al. (2018) capaz de propor-

cionar uma experiência imersiva e interativa de musculação para o usuário, unindo realidade virtual com a internet das coisas. O assistente utiliza pequenos sensores sem fio removíveis que podem ser anexados a máquinas de exercícios de forma a captar informações a respeito do tipo de exercício, contagem de repetições e progresso em tempo real. Baseado nos dados extraídos, JARVIS mostra para o usuário a forma correta de executar determinado exercício, instruções sobre a postura, quais músculos estão sendo trabalhados e quais precisam de foco, similar às informações que este trabalho propõe possibilitar ao usuário por meio da análise do treinador. Contudo, JARVIS trabalha com realidade virtual, uma tecnologia ainda pouco acessível no Brasil, além de utilizar sensores no maquinário da academia que configuram uma execução estática. A proposta deste trabalho é dinâmica e acessível, pesos livres ocupam pouco espaço e possuem custo muito mais baixo em relação ao maquinário fixo presente nas academias.

MPTrain é um sistema *mobile* apresentado por Oliver e Flores-Mangas (2006) que utiliza música de forma adaptativa para auxiliar o usuário a atingir seus objetivos de forma mais eficiente. O treino desejado, em termos de frequência de batimentos cardíacos através do tempo, deve ser fornecido como entrada e o sistema irá constantemente monitorar a fisiologia e o movimento do usuário a fim de determinar qual música enfileirar na *playlist* no decorrer daquela atividade. O MPTrain explora muito bem a conexão *sensor-mobile*, porém o foco na frequência cardíaca e a análise que o sistema faz do movimento não incorrem na identificação do exercício e sim no ritmo. Dessa forma, o MPTrain é voltado para exercícios aeróbicos, diferentes dos que são realizados na musculação. Além disso, nenhum histórico é mantido para analisar progressos ou classificações, tornando o MPTrain totalmente voltado para o momento de execução.

Um aplicativo de monitoramento de atividades físicas foi desenvolvido por Karandikar et al. (2019) onde acelerômetros analisam as informações e as enviam para um serviço de banco de dados na nuvem por meio de um microcontrolador com módulo Wi-Fi. O aplicativo faz a interação com o usuário, reduzindo a alimentação manual de dados (que costuma ser imprecisa). A identificação do usuário deu-se por meio da tecnologia RFID. O sistema foi desenvolvido para tornar a rotina de exercícios mais precisa e menos tediosa, provendo uma solução mais em conta ao invés de atualizar o conjunto de equipamentos do ginásio. Os dados são lidos com precisão, sem a necessidade de cálculos manuais. A comunicação sincronizada com um ponto de acesso durante a execução dos exercícios também foi proposta por este trabalho, a diferença é que o processamento dos dados foi usado para identificar o exercício, enquanto que o aplicativo abordado utilizou o sensoriamento para contagem de séries e repetições.

Um sistema computacional baseado em Redes de Sensores Sem Fio (RSSFs) foi proposto por Mota (2017) para análise biomecânica da marcha. Os nós sensores utilizados foram compostos de um microcontrolador ESP8266 com módulo Wi-Fi conectado a um módulo inercial MPU-6050 que funciona com seis eixos: três eixos para aceleração e três eixos para o giroscópio. Após a leitura dos movimentos, um computador base era acionado para modelar os dados lidos e assim determinar a consistência dos movimentos. O trabalho de Mota (2017) se assemelha ao nosso em relação ao uso do microcontrolador ESP8266, do módulo MPU6050 e um computador base como meio de acesso e processamento com o objetivo de reconhecimento do movimento humano em atividades físicas. Contudo, neste projeto os nós sensores foram anexados diretamente sobre os pesos livres, nenhum sensor foi anexado ao corpo do praticante. O foco esteve no reconhecimento de atividades variadas utilizando os pesos livres, diferente do trabalho de Mota (2017) que tinha como foco a análise da marcha.

4 METODOLOGIA

Nesta seção serão apresentados os processos, técnicas e meios que foram utilizados no desenvolvimento do projeto. A primeira parte apresenta os equipamentos que foram utilizados e suas características, a segunda parte apresenta os meios de calibração dos sensores e infraestrutura de comunicação, em seguida são apresentados os exercícios que compuseram a dinâmica de análise desse trabalho, por fim são detalhadas as formas de coleta e preparação dos dados.

4.1 Equipamentos


Para decidir qual microcontrolador pode melhor atender uma demanda, Mazidi, Naimi e Naimi (2010, p. 43) definiram três critérios a serem considerados:

- a) custos efetivos e eficiência em relação ao que é demandado pelo projeto, leva-se em conta necessidades como: velocidade, armazenamento, consumo de energia, processamento, facilidade de atualização e quantidade de pinos de entrada e saída;
- b) facilidade, adaptabilidade e compatibilidade dos meios de desenvolvimento dos produtos relacionados ao projeto (e. g. integrações, bibliotecas e IDEs);
- c) disponibilidade atual e futura do microcontrolador a nível quantitativo, importante para o segmento comercial.

Levando os critérios acima em consideração, foi escolhido para este trabalho o microcontrolador ESP8266 WiFi SOC com módulo NodeMCU (Figura 4.1). Essa escolha se deu pelo seu potencial para aplicações de baixo custo, já incluir módulo Wi-Fi, contar com ambientes de desenvolvimento baseado em Lua, Arduino e RTOS (com integrações inclusas e de fácil realização) e também por possuir alta compatibilidade com módulos periféricos popularizados para Arduino (OLIVEIRA, 2017). O módulo NodeMCU é um *firmware* de código aberto baseado em Lua para o microcontrolador ESP8266, implementado em C, suportado pela comunidade, executável em qualquer módulo ESP e com modelo de programação similar ao Node.js (NODEMCU, 2021).

De forma similar, aplicando os mesmos critérios aos sensores inerciais, foi escolhido o módulo MPU-6050 (Figura 4.2), um sensor com três conversores analógico-para-digital (ADC – *Analog-to-Digital Converter*) de 16-bit para digitalização das saídas do giroscópio e três ADCs de 16-bit para as saídas do acelerômetro, configurando assim uma IMU (sessão 2.3.1). Além disso, o MPU-6050 conta com um *buffer* de fila de 1024 bytes e um sensor de temperatura.


Figura 4.1 – ESP8266 sobre Protoboard



Fonte: Do autor (2021).

A comunicação com todos os registradores do dispositivo é realizada utilizando o barramento inter-circuito-integrado (I^2C – *Inter-Integrated Circuit*) a 400kHz. Opera a uma faixa de voltagem de 2,37V – 4,46V totalmente compatível com a potência do ESP8266 que opera com voltagem de 3,30V – dados da ficha técnica oficial (INVENSENSE, 2013, p.7-11).

Figura 4.2 – MPU-6050



Fonte: Do autor (2021).

Para alimentar energeticamente o ESP8266 foi utilizada uma bateria SD 18650 recarregável de lítio com capacidade de 9800 mAh e tensão de 4,2V, recarregada por meio de um carregador de baterias de lítio universal modelo TG-088 com capacidade de alimentação de 100 a 240V e com saída (carregamento) de 3,7V/1000mA – informações impressas nos próprios produtos (Figura 4.3). Para conectar a fonte de alimentação ao microcontrolador foi utilizado um módulo *shield* de baterias 18650 para ESP32 compatível com ESP8266 (Figura 4.4), com conector micro USB, corrente de carregamento 0,5A, 1 chave de saída USB, tensão de entrada máxima de 8V, 3 interfaces de saída de 3V e 3 de 5V, composta por placa de fenolite e compo-

mentos eletrônicos (ELETROGATE, 2022).

Figura 4.3 – Bateria e carregador



Fonte: Do autor (2023).

Figura 4.4 – Módulo Shield Bateria 18650 para ESP32



Fonte: Adaptado de ELETROGATE (2022).

Os pesos livres que compuseram este trabalho foram anilhas com carga de 1kg (Figura 4.5), pois uma carga pequena promove maior precisão na execução dos movimentos e, uma vez que é um objetivo deste trabalho a análise dos movimentos e não a reação do músculo, esta carga se mostrou ideal para tornar o espaço amostral mais estável. O microcontrolador e o sensor inercial foram anexados individualmente em *protoboards* para condução dos sinais elétricos, conectados entre si por meio de *jumpers* e, em conjunto com o módulo *shield* já


comportando a bateria SD 186550, foram anexados a uma das anilhas de forma a deixar livre uma das áreas de pegada (Figura 4.6).

Figura 4.5 – Anilhas



Fonte: Do autor (2023).

Figura 4.6 – Anilha sensorizada em atividade e pegada



Fonte: Do autor (2023).

A escrita dos códigos, o processamento de dados e a análise dos resultados foram realizados em um notebook com sistema operacional “Pop!_OS”, uma distribuição Linux com gerenciadores de pacote nativamente voltados para engenharia de dados e *deep learning* (SYSTEM 76, 2023), além de também ser utilizado como um ponto de acesso na rede local, estabelecida por meio de um *smartphone* com sistema operacional Android com suporte a tecnologia de roteamento Wi-Fi.

4.2 Calibragem e comunicação

O MPU-6050 é configurado neste projeto para atuar com faixa de acelerômetro de $\pm 4g$ ($\pm 39,2 \text{ m/s}^2$), faixa de giroscópio de $250^\circ/\text{s}$ e filtro de largura de banda de 21 Hz. Quando o equipamento é ativado, e a corrente elétrica começa a circular pelos periféricos, o microcontrolador ativará essas configurações no sensor inercial e em seguida se dará a sua calibração que ocorre com base no cálculo dos *offsets*⁹. Para isso, se define um tempo estimado para a calibração no qual serão realizadas n leituras de todos os eixos (I). Cada *offset* (σ) de uma unidade inercial, que corresponde a cada eixo do acelerômetro e do giroscópio, é calculado por meio da soma de todas as leituras durante o tempo estipulado – onde o sensor deverá estar estático –, dividido pela quantidade de leituras (Equação 4.1). Isso é necessário pois é comum que os dispositivos apresentem alguns erros de precisão e sensibilidade a ruídos.

$$\sigma = \left(\sum_{i=1}^n |I_i| \right) / n \quad (4.1)$$

Tabela 4.1 – Exemplo de leitura quando o sensor está parado

Unidade inercial	Esperado	Valor Lido (I)	Offset (σ)	Final ($I - \sigma$)
Acelerômetro no eixo x	0,0	-0,35	0,3	-0,05
Acelerômetro no eixo y	0,0	1,2	1,3	-0,1
Acelerômetro no eixo z	9,8	9,67	0,12	9,55
Giroscópio no eixo x	0,0	-0,01	0,17	0,16
Giroscópio no eixo y	0,0	0,02	0,01	0,01
Giroscópio no eixo z	0,0	0,0	0,01	-0,01

Fonte: Do autor (2023).

A tabela 4.1 exemplifica a ação dos *offsets* no resultado final. Nota-se que o cálculo final ($I - \sigma$) de uma leitura faz com que ela se aproxime do esperado na maioria dos casos. Contudo, alguns resultados se distanciam mais do real quando o *offset* é aplicado, como no

⁹Valor de desvio em relação ao valor esperado.

eixo Z do acelerômetro da tabela mencionada: o valor esperado é a aceleração da gravidade no eixo em questão, o valor lido foi menor que o esperado, a diminuição do *offset* fez o resultado final ser um valor ainda menor (mais distante do esperado). Quando se sabe o valor esperado é possível fazer uma verificação simples para somar o *offset* ao invés de subtrair se a soma o aproximar mais do valor esperado, no entanto, quando o sensor está em movimento é impraticável conceber o valor esperado ponto a ponto, o que torna essa verificação inviável. Além disso, o eixo que sofre interferência da gravidade muda conforme o movimento rotaciona o sensor, o que também não se pode prever ponto a ponto dos dados puros.

Para melhorar o processo de calibração e diminuir a interferência da aceleração da gravidade, foi aplicado um filtro digital (Equação 4.2) além dos *offsets* já definidos. Esse filtro inicia-se com a declaração de uma variável de aceleração gravitacional g . para cada unidade inercial de aceleração (a aceleração da gravidade não interfere nos giroscópios), tendo-se assim as variáveis g_x , g_y e g_z , inicializadas respectivamente com os valores 0, 0 e g (9,8). A base do filtro é uma constante α que determina a porcentagem que é mantida do valor adquirido no momento presente e a porcentagem de influência do novo valor vindo para compôr o histórico gerido pelo microcontrolador – neste trabalho o valor de α foi 0,8.

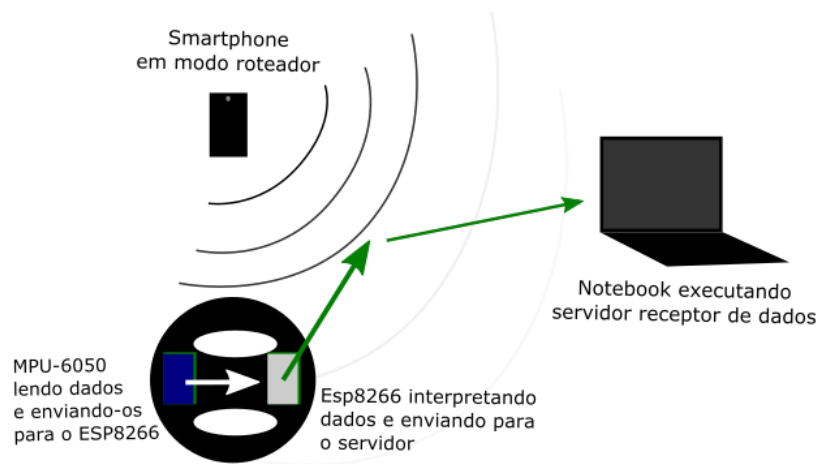
$$g. = \alpha \cdot g. + (1 - \alpha) \cdot (I - \sigma) \quad (4.2)$$

Após a calibração, o microcontrolador ativa seu módulo Wi-Fi para se conectar à rede local sendo roteada pelo *smartphone*. Todos os dispositivos devem estar dentro dessa rede para que se possa estabelecer uma comunicação via *socket*. Também conhecida como comunicação de dois caminhos, esse tipo de conexão fornece comunicação entre duas pontas por meio do endereço IP e porta (Figura 4.8). A partir disso, o microcontrolador consegue interpretar os dados do sensor, deduzir de cada eixo seu *offset* (definido na calibração), adicionar o dado de tempo da execução (para organização dos pacotes) e realizar seu envio pela rede através da comunicação via *socket* com o servidor (Figura 4.7).


4.3 Exercícios analisados

Ao monitorar a execução de uma variedade de exercícios é possível observar que muitos compartilham movimentos de grande similaridade. Portanto, para validar a eficiência do método foram escolhidos exercícios com muitos pontos em comum em suas movimentações,

Figura 4.7 – Infraestrutura de comunicação



Fonte: Do autor (2023).

Figura 4.8 – Comunicação via *socket*

Fonte: Tedesco (2019).

mas que trabalham grupos musculares diferentes e que podem ser realizados com pesos livres, sendo eles: tríceps francês (Figura 4.9), rosca neutra/direta (Figura 4.10), desenvolvimento de ombros (Figura 4.11) e passada (Figura 4.12). Todos os exercícios foram realizados pelo autor utilizando as anilhas em uma posição fixa, isso foi importante pois as amostras coletadas nos eixos do MPU-6050 seriam diferentes se fossem trabalhadas posições diferentes.

Figura 4.9 – Execução de exercício: tríceps francês



Fonte: Do autor (2023).

Figura 4.10 – Execução de exercício: rosca direta



Fonte: Do autor (2023).

Figura 4.11 – Execução de exercício: desenvolvimento de ombros



Fonte: Do autor (2023).

Figura 4.12 – Execução de exercício: passada



Fonte: Do autor (2023).

4.4 Coleta de dados

Cada série de um exercício é um espaço amostral, onde cada amostra é uma leitura (quadro 4.1) e cada repetição um conjunto amostral. Os passos para realizar cada coleta foram os seguintes:

- a) iniciar a rede local ativando o roteamento via *smartphone*;
- b) definir o número de repetições que serão coletadas;
- c) iniciar o servidor baseado em *socket* para receber os dados;
- d) posicionar o usuário na posição de largada do exercício (lado esquerdo das figuras 4.9 - 4.12);
- e) ligar o módulo *shield*, liberando energia para o microcontrolador;
- f) aguardar o LED do microcontrolador iniciar sinal intermitente no LED integrado, indicando que as leituras foram iniciadas;
- g) no lado do servidor, acionar tecla de marcação indicando que uma repetição foi concluída (quando o exercício volta para a posição de largada).

Quadro 4.1 – Amostra de dados coletada a cada leitura

Variável	Descrição
<i>millis</i>	Tempo de execução do microcontrolador em milissegundos ($s/1000$) quando a leitura foi feita
a_x	Aceleração no eixo X
a_y	Aceleração no eixo Y
a_z	Aceleração no eixo Z
g_x	Velocidade angular de giro no eixo X
g_y	Velocidade angular de giro no eixo Y
g_z	Velocidade angular de giro no eixo Z

Fonte: Do autor (2023).

Foram colhidos 300 conjuntos amostrais, compostos por uma média de 120 amostras, divididos entre 5 espaços amostrais, sendo um para cada exercício (Seção 4.3) mais um para identificação de não-movimento (parado). A tabela 4.2 mostra a composição final de amostragem adotada.

Tabela 4.2 – Quantificação de coletas realizadas

Espaço Amostral	Número de Conjuntos	Total de Amostras
Desenvolvimento de Ombros	80	14.400
Passada	40	7.200
Rosca Direta	80	12.800
Tríceps Francês	40	4.800
Parado	60	6.240
Total:	300	45.440

Fonte: Do autor (2023).


4.5 Visualização

Durante o processo de desenvolvimento do processamento dos dados e da integração com a biblioteca *scikit-learn*, observou-se a necessidade de uma forma de validar se os dados e seus fluxos estavam congruentes com o esperado. Assim, foram desenvolvidas e aplicadas técnicas de análise e visualização das leituras dos sensores, e também foram exploradas ferramentas da própria biblioteca utilizada, como a visualização da árvore de decisão (Figura 5.3).

Foi desenvolvido um visualizador de rotações (Figura 4.13) em javascript utilizando a biblioteca Processing (PROCESSING FOUNDATION, 2022), onde foram avaliados os efeitos dos desvios advindos do acelerômetro e detalhados na seção 2.3.1. Neste visualizador, um halter foi modelado e projetado em três dimensões para imitar os movimentos de rotação do protótipo de sensoriamento com o intuito de validar a eficiência dos giroscópios. A velocidade angular dos giroscópios foram utilizadas para calcular a matriz de rotação (Equação 4.3) baseada nos ângulos de Euler, aplicando rotação primeiro no eixo Z (ϕ), depois no eixo Y (θ) e finalmente no eixo X (ψ) (STANČIN; TOMAŽIČ, 2018).

$$\begin{aligned}
 R &= R_{Z,\phi} \cdot R_{Y,\theta} \cdot R_{X,\psi} \\
 &= \begin{bmatrix} \cos \phi \cos \theta & \cos \phi \sin \theta \sin \psi - \sin \phi \cos \psi & \cos \phi \sin \theta \cos \psi + \sin \phi \sin \psi \\ \sin \phi \cos \theta & \sin \phi \sin \theta \sin \psi + \cos \phi \cos \psi & \sin \phi \sin \theta \cos \psi - \cos \phi \sin \psi \\ -\sin \theta & \cos \theta \sin \psi & \cos \theta \cos \psi \end{bmatrix} \quad (4.3)
 \end{aligned}$$

Figura 4.13 – Visualizador de rotações alimentado pela saída de dados do MPU-6050



Fonte: Do autor (2023).

4.6 Preparação dos dados e classificação dos exercícios

Quando os pacotes chegam no servidor enviados pelo microcontrolador, são salvos em arquivo com formatação CSV (*comma-separated values*) que separa os dados por um caractere especial específico, no caso foi utilizado o ponto-e-vírgula (;). Esse arquivo é então utilizado ao fim das leituras como entrada para um algoritmo preparador, responsável por:


- carregar os dados em uma estrutura de matriz, onde cada coluna representa uma unidade inercial;
- formatar os dados por meio da aplicação de filtros de média para suavização de ruídos;
- calcular média e desvio padrão de cada unidade inercial do conjunto amostral.

Mesmo com a filtragem digital de redução da interferência gravitacional e a calibragem

com os *offsets*, os sensores ainda estão suscetíveis a ruídos que prejudicam a análise dos dados, é devido a isso que o algoritmo preparador realiza um filtro duplo de média cuja aplicação se pode ver a partir do gráfico presente na figura 4.14. O gráfico mostra, de cima para baixo, os dados de um conjunto amostral de um exercício de passada nos eixos x , y e z , e tem-se: em azul os dados recebidos direto do microcontrolador, em vermelho a primeira aplicação do filtro e em amarelo a segunda aplicação. Essa divisão em duas etapas do filtro de média é importante pois a primeira não é suficiente para suavizar todos os ruídos, e se a intensidade do filtro for aumentada ele distorce as curvas tornando a análise imprecisa. É perceptível que alguns eixos sofrem mais oscilações do que outros, no exemplo apresentado o eixo Z foi o mais ruidoso dos três – também há dois exemplos nos apêndices A e B deste documento, mostrando todos os eixos de um conjunto amostral de rosca direta e desenvolvimento de ombros. Neste trabalho o filtro contou com um alcance de ± 15 leituras, de forma que o algoritmo calcula o valor de um ponto baseado na média das quinze leituras anteriores e nas quinze posteriores.

Os dados preparados são salvos no arquivo de treinamento. Lá, cada conjunto amostral é salvo em uma única linha, contendo a média de cada unidade inercial mais o identificador do exercício. Após preparar todos os espaços amostrais, parte dos dados do arquivo de treinamento são movidos para um novo arquivo que foi utilizado como testes para validar a eficiência dos exercícios. O arquivo de treinamento e o arquivo de testes são usados pelos algoritmos do *scikit-learn* para chegar aos resultados que serão apresentados na seção a seguir.

Figura 4.14 – Filtro duplo de média aplicado aos eixos do giroscópio para a passada



Fonte: Do autor (2023).

5 RESULTADOS

Todos os algoritmos utilizados passaram por testagens em suas configurações e métodos, e as configurações detalhadas no quadro 5.1 foram responsáveis pelos resultados que serão apresentados e discutidos nesta seção. Também estarão relatados a contribuição realizada e os trabalhos que poderão ser seguidos a partir deste.

Quadro 5.1 – Configurações dos algoritmos

Algoritmo	Configurações
MLP	<p>Função de ativação: de unidade de retificação linear $f(x) = \max(0, x)$</p> <p>Solucionador de otimização de pesos: <i>lbfgs</i> da família dos métodos quasi-Newton</p> <p>Termo de regularização L2: 0, 1</p> <p>Número máximo de funções de perda: 1.000</p> <p>Camadas ocultas: 2, uma com 10 e a outra com 4 neurônios</p>
kNN	<p>Número de vizinhos para verificação (k): 6</p> <p>Função de peso para predição baseada em: distância</p> <p>Método de cálculo de distância: Euclidiana</p> <p>Algoritmo base: KD Tree para problemas de geração rápida de N-pontos</p>
DT	<p>Critério para avaliação de divisões: entropia</p> <p>Estratégia de escolha de divisão em nó: escolha da melhor divisão</p> <p>Profundidade máxima da árvore: ilimitada</p> <p>Número mínimo de amostras para subdividir um nó: 4</p>

Fonte: Do autor (2023).

Os dados preparados foram separados em um arquivo com o rótulo de cada conjunto devidamente identificado. Em seguida, os dados foram distribuídos aleatoriamente, sem perder

sua estrutura, em arquivos auxiliares para impulsar a dinâmica das etapas. Foram gerados cinco espaços amostrais para treinamento e cinco espaços amostrais para testes com 265, 215, 150, 85 e 35 conjuntos amostrais respectivamente. Os espaços foram testados em contraste para cada algoritmo, organizados nos seguintes cenários:

- a) espaço de treinamento com 265 conjuntos \times espaço de testes com 35 conjuntos;
- b) espaço de treinamento com 215 conjuntos \times espaço de testes com 85 conjuntos;
- c) espaço de treinamento com 150 conjuntos \times espaço de testes com 150 conjuntos;
- d) espaço de treinamento com 85 conjuntos \times espaço de testes com 215 conjuntos;
- e) espaço de treinamento com 35 conjuntos \times espaço de testes com 265 conjuntos.

Estes testes foram feitos com o objetivo de analisar a acurácia dos algoritmos para conjuntos de teste pequenos quando foram amplamente treinados – casos a) e b) –, conjunto de teste do mesmo tamanho que o conjunto de treinamento – caso c) – e, por fim, conjunto de teste grande para pouco treinamento – casos d) e e). Todos os testes de acurácia foram realizados utilizando o método *accuracy_score* da classe *metrics* da própria biblioteca *scikit-learn*.

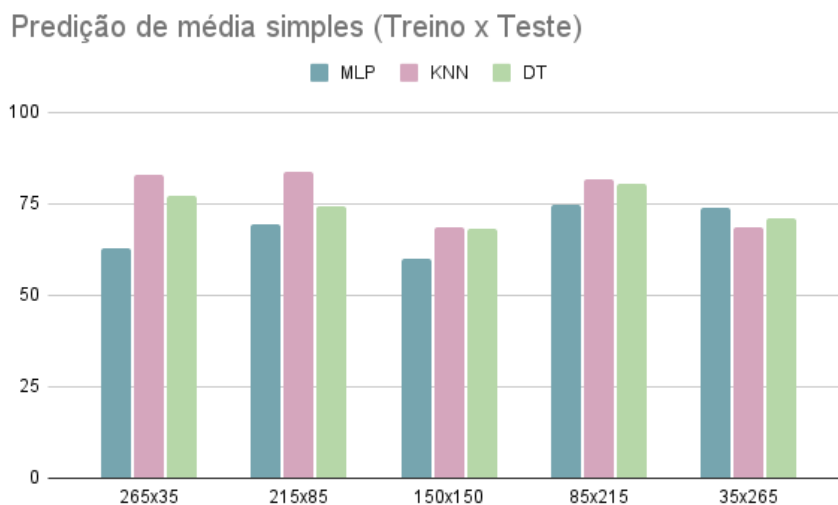
Tabela 5.1 – Acurácia geral dos algoritmos usando amostragem de média simples

Referência	265x35	215x85	150x150	85x215	35x265	Desvio padrão (DP)
MLP	62,86%	69,41%	60,00%	74,88%	73,96%	6,61%
kNN	82,85%	83,53%	68,67%	81,60%	68,67%	7,69%
DT	77,14%	74,11%	68,00%	80,46%	70,94%	4,92%

Fonte: Do autor (2023).

Inicialmente, os algoritmos foram treinados para conjuntos contendo a média geral de cada eixo no decorrer de uma repetição do exercício o qual fazia referência. Com essa faixa de seis dados por conjunto (três eixos do acelerômetro e três eixos do giroscópio), extremamente generalizado, foram obtidos os resultados apresentados na tabela 5.1 e representados pela figura 5.1, onde os algoritmos de MLP e DT obtiveram o seu melhor desempenho no cenário d) enquanto que para o kNN foi no cenário a). Para este espaço de testes, nenhum dos algoritmos analisados obteve acurácia superior a 85%. O algoritmo DT teve a maior estabilidade entre os cenários, com desvio padrão de 4,92% e o kNN foi o menos estável, com desvio padrão de 7,69%.

Figura 5.1 – Gráfico de acurácia geral usando amostragem de média simples



Fonte: Do autor (2023).

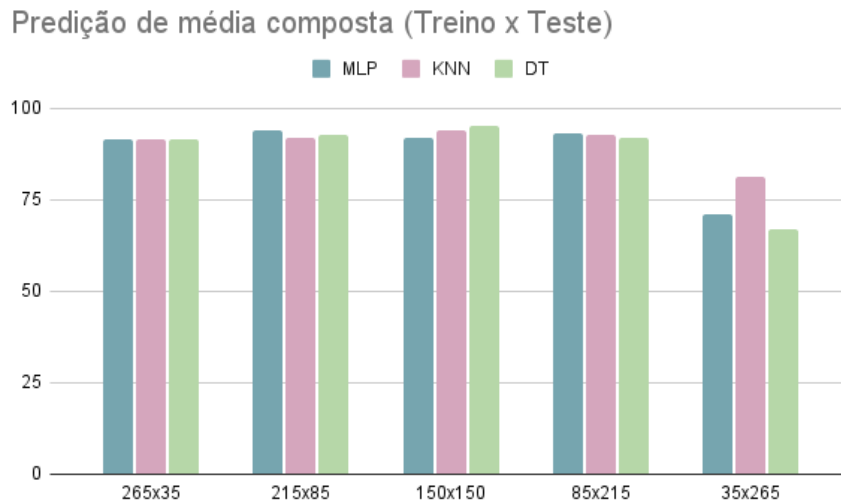
Tabela 5.2 – Acurácia geral dos algoritmos usando amostragem de média de composição

Referência	265x35	215x85	150x150	85x215	35x265	Desvio padrão (DP)
MLP	91,43%	94,11%	92,00%	93,02%	70,94%	9,76%
kNN	91,43%	91,76%	94,00%	92,56%	81,13%	5,15%
DT	91,43%	92,94%	95,34%	92,09%	66,79%	11,79%

Fonte: Do autor (2023).

Após isso, foi realizado um outro processamento que ao invés de reduzir os dados à média geral de cada eixo de cada unidade inercial, o conjunto de amostras foi dividido em dez partes, onde a média de cada parte para cada eixo de cada unidade inercial é que foi processada, resultando em 60 dimensões por conjunto ao invés de 6. Essa expansão dos dados permitiu captar a média em pontos específicos do exercício que permitiram compreender o comportamento dos valores de forma mais assertiva, como pode ser comprovado nos dados apresentados na tabela 5.2 e observado na figura 5.2. Neste novo ambiente de testes, os três algoritmos atingiram o mesmo resultado para o cenário a), o que denota que o espaço de teste muito pequeno se estabilizou no novo ambiente de teste, o algoritmo MLP obteve seu melhor resultado no cenário b), e os algoritmos kNN e DT obtiveram seus melhores resultados no cenário c). Em relação

Figura 5.2 – Gráfico de acurácia geral usando amostragem de média de composição

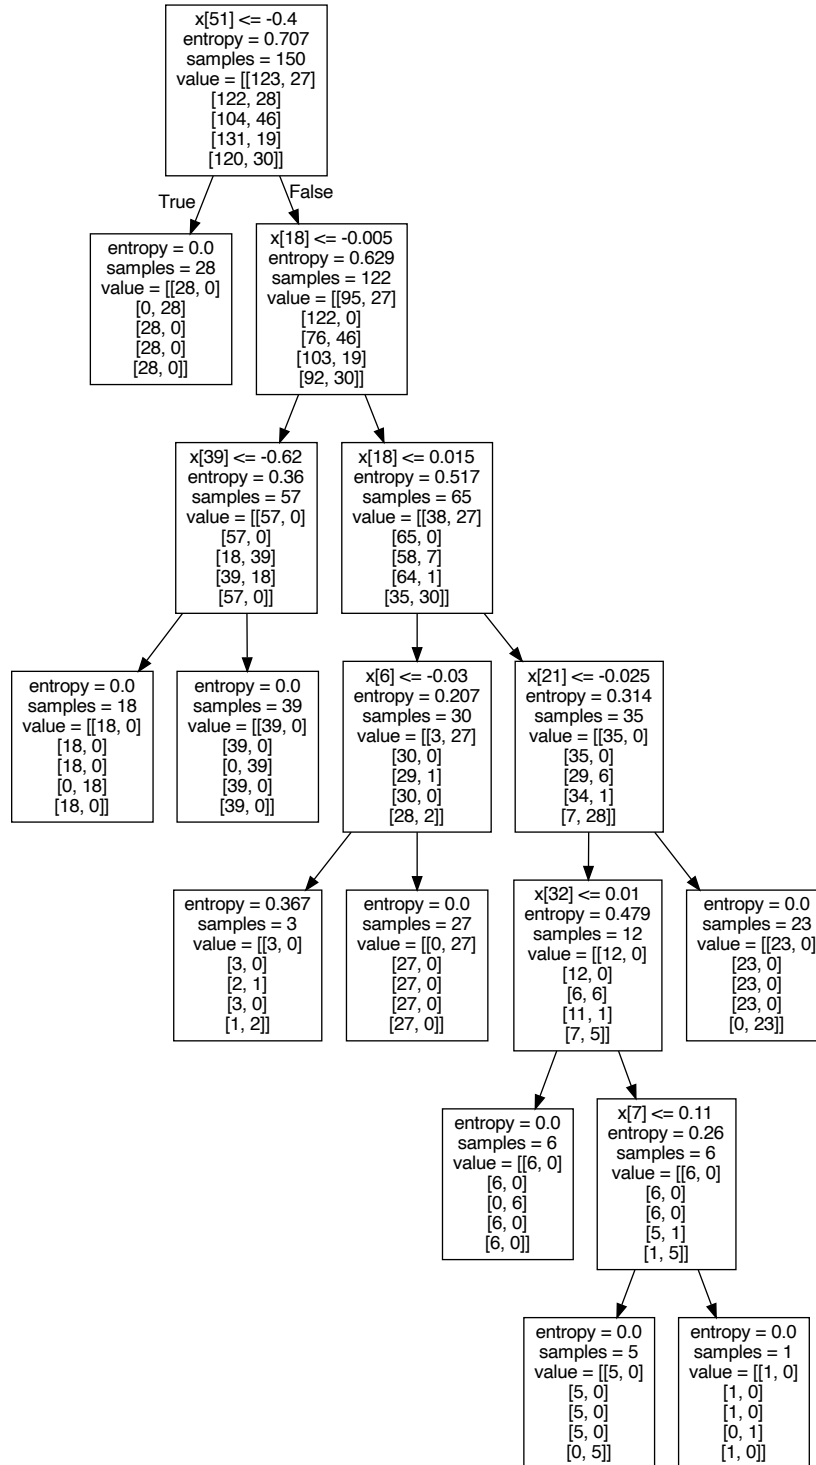


Fonte: Do autor (2023).

à estabilidade, os algoritmos kNN e DT se inverteram, o kNN foi o mais estável com desvio padrão de 5,15% enquanto que o DT teve desvio padrão de 11,79%.

A partir destes resultados é possível verificar constatações vistas no referencial teórico em relação aos algoritmos utilizados. Enquanto a dimensionalidade do conjunto de manteve pequena, a árvore de decisão esteve estável, funcionando bem com poucos recursos de treinamento e atingindo níveis de acurácia acima de 68%. Quando a dimensionalidade foi aumentada, no entanto, o DT teve dificuldades com um conjunto de treinamento muito pequeno, embora manteve sua estabilidade nos outros cenários, com acurácia superior a 91%. Comparando o crescimento da dimensionalidade, o kNN se mostrou o mais estável a mudança, aumentando sua acurácia geral média de 69,41% para 92% e diminuindo seu desvio padrão de 7,69% para 5,15%, diferente dos outros algoritmos que tiveram aumento no desvio.

Figura 5.3 – Exemplo de árvore de decisão gerada pelo *scikit-learn*



Fonte: Do autor (2023).

6 CONCLUSÃO

Os resultados desta pesquisa mostraram que, para espaços amostrais oriundos de uma única pessoa para ela mesma, é possível identificar os exercícios realizados com níveis de acurácia superiores a 90% com equipamentos de baixo custo quando comparados a aparatos como câmeras especializadas e sensores mais tecnológicos. Além disso, este trabalho reuniu diversos segmentos da área da tecnologia e da saúde que tem muito potencial de melhorarem a qualidade de vida das pessoas, formando mais um elo nas pesquisas que envolvem a internet das coisas e, portanto, o futuro das telecomunicações.

6.1 Contribuição e trabalhos futuros

Embora se encontre com facilidade na literatura conteúdos sobre análise de movimento humano, modelos de academias inteligentes e equipamentos fitness que estão sendo agregados à era da internet das coisas, é muito difícil encontrar pesquisas específicas em pesos livres e as dinâmicas que envolvem a integração tecnológica e acompanhamento de atividades físicas assincronamente de forma eficiente, acessíveis e sem o uso de aparatos que podem prejudicar a locomoção do usuário ou causar incômodos. Assim, este trabalho culminou em uma aplicação de baixo custo para a identificação, com altas taxas de acurácia, de exercícios físicos com pesos livres, contribuindo para o avanço de estudos na área de internet das coisas voltadas para o mercado e ambiente de *fitness*, bem como para a área de análise de movimentos através de equipamentos móveis com alto grau de liberdade.

É possível avançar mais neste estudo, indo a campo para coletar dados de diversos usuários para certificar e aprimorar técnicas de inteligência artificial que possam não só identificar os exercícios que estão sendo realizados, mas qualificar a sua execução; criar ferramentas de interação direta entre treinador e aluno para discutir a execução e acompanhamento dos treinos com mais precisão; e também é possível alcançar outras áreas da saúde como a fisioterapia, onde a integração de pesos e equipamentos de alta mobilidade para utilização por pacientes em estado avançado de reabilitação permitiria o acompanhamento remoto por parte dos fisioterapeutas, proporcionando respostas mais precisas.

REFERÊNCIAS

ACAD. **Academias enfrentam impactos do COVID-19**. 89. ed. Rio de Janeiro: Associação Brasileira de Academias, abr. 2020.

ALMEIDA, Marco Antonio Bettine de et al. Jogos Olímpicos Gregos: discussões históricas. **Lecturas: Educación Física y Deportes**, Revista Digital EFDeportes, Buenos Aires, v. 17, n. 169, jun. 2012.

ARAUJO, Gustavo Cesar Cota. **Comparação do método excêntrico com o método concêntrico na hipertrofia muscular: uma revisão sistemática**. Ouro Preto: Escola de Educação Física, Universidade Federal de Ouro Preto, 2022. f. 29.

BARON, R.; PLAMONDON, R. Acceleration measurement with an instrumented pen for signature verification and handwriting analysis. **IEEE Transactions on Instrumentation and Measurement**, v. 38, n. 6, p. 1132–1138, dez. 1989. DOI: [10.1109/19.46414](https://doi.org/10.1109/19.46414).

BENSER, Earl T. Trends in inertial sensors and applications. **2015 IEEE International Symposium on Inertial Sensors and Systems (ISISS) Proceedings**, p. 1–4, mar. 2015.

BHATIA, Munish; SOOD, Sandeep K. An intelligent framework for workouts in gymnasium: M-Health perspective. **Computers & Electrical Engineering**, Elsevier, v. 65, p. 292–309, 2018.

CAPINUSSÚ, José Maurício. Academias de ginástica e condicionamento físico: origens. **Atlas do esporte no Brasil**. Rio de Janeiro: CONFEEF, p. 57–69, 2006.

CAVALLI, Olga; MEINERS, F. Internet das coisas e inovação na América Latina, 2016.

CHAKRAVARTY, Pritish et al. A novel biomechanical approach for animal behaviour recognition using accelerometers. **Methods in Ecology and Evolution**, v. 10, n. 6, p. 802–814, 2019. DOI: <https://doi.org/10.1111/2041-210X.13172>.

CHALINE, Eric. Panathenaic Way to Fitness. **History Today**, v. 65, n. 2, p. 3–4, fev. 2015.

CHAN, John S. Y. et al. Special Issue – Therapeutic Benefits of Physical Activity for Mood: A Systematic Review on the Effects of Exercise Intensity, Duration, and Modality. **The Journal of Psychology**, Routledge, v. 153, n. 1, p. 102–125, 2019.

CHARBUTY, Bahzad; ABDULAZEEZ, Adnan. Classification based on decision tree algorithm for machine learning. **Journal of Applied Science and Technology Trends**, v. 2, n. 01, p. 20–28, 2021.

DESPLENTER, Tyler et al. Extension of the WearME framework for EMG-driven control of a wearable assistive exoskeleton. **2016 IEEE International Conference on Advanced Intelligent Mechatronics (AIM)**, p. 288–293, 2016. DOI: [10.1109/AIM.2016.7576781](https://doi.org/10.1109/AIM.2016.7576781).

ELETROGATE. **Módulo Shield Bateria 18650 para ESP32**. 2022. Disponível em: <<https://www.eletrogate.com/modulo-shield-bateria-18650-para-esp32>>. Acesso em: 11 fev. 2023.

ERDAŞ, Ç. Berke et al. Integrating Features for Accelerometer-based Activity Recognition. **Procedia Computer Science**, v. 98, p. 522–527, 2016. The 7th International Conference on Emerging Ubiquitous Systems and Pervasive Networks (EUSPN 2016)/The 6th International Conference on Current and Future Trends of Information and Communication Technologies in Healthcare (ICTH-2016)/Affiliated Workshops. ISSN 1877-0509. DOI: <https://doi.org/10.1016/j.procs.2016.09.070>.

FALCÃO, Heráclito Santos et al. Classificação de vagas de estacionamento com utilização de rede perceptron multicamadas. **Revista de Sistemas de Informação da FSMA, Visconde de Araújo**, v. 12, p. 41–48, 2013.

FANUCCHI, Rodrigo Zempulski; OLESKOVICZ, MARIO; BARBOSA, DANIEL. Análise da detecção de faltas de alta impedância utilizando redes neurais artificiais com topologias baseadas em perceptron multicamadas e redes rbf. **Simpósio Brasileiro de Automação Inteligente (SBAI), Fortaleza**, 2013.

FERREIRA, Fernando. Síntese da história do desporto. **Povos e Culturas**, Universidade Católica Portuguesa, Lisboa, Portugal, n. 9, p. 151–172, jan. 2004.

GOYAL, Parul et al. Internet of Things: Applications, security and privacy: A survey. **Materials Today: Proceedings**, 2020. ISSN 2214-7853.

HALL, Susan Jean. **Biomecânica básica**. Tradução: Dilza Balteiro Pereira de Campos e Douglas Arthur Omena Futuro. 6. ed. Barueri, São Paulo: Editora Guanabara Koogan Ltda, 2013.

HAMDAN, Nur Al-huda; VOELKER, Simon; BORCHERS, Jan. Sketch&Stitch: Interactive Embroidery for E-Textiles. **Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems**, Association for Computing Machinery, Montreal QC, Canada, p. 1–13, 2018. DOI: [10.1145/3173574.3173656](https://doi.org/10.1145/3173574.3173656).

HARRINGTON, M E; DANIEL, R W; KYBERD, P J. A Measurement System for the Recognition of Arm Gestures Using Accelerometers. **Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine**, v. 209, n. 2, p. 129–134, 1995. PMID: 7495428. DOI: [10.1243/PIME_PROC_1995_209_330_02](https://doi.org/10.1243/PIME_PROC_1995_209_330_02).

HASSAN, Mohammed Mehedi et al. A robust human activity recognition system using smartphone sensors and deep learning. **Future Generation Computer Systems**, v. 81, p. 307–313, 2018.

HORVATH, Juliane et al. Structural and functional correlates of smartphone addiction. **Addictive behaviors**, Elsevier, v. 105, p. 106–334, 2020.

IEEE RAS UFCG. **Curiosidades: O que é um microcontrolador?** 2020. Disponível em: <<https://edu.ieee.org/br-ufcgras/o-que-e-um-microcontrolador/>>. Acesso em: 23 mai. 2021.

IHRSA, RELATÓRIO GLOBAL. Fitness cresce no mundo e Brasil ainda sofre com a crise econômica. **Revista ACAD Brasil**, ago. 2017.

INVENSENSE. **MPU-6000 and MPU-6050 Product Specification**. 1197 Borregas Ave, Sunnyvale, CA 94089 U.S.A., 19 ago. 2013. 52 p. Revision 3.4. Disponível em: <<https://invense.nse.tdk.com/wp-content/uploads/2015/02/MPU-6000-Datasheet1.pdf>>.

IOSA, Marco et al. Wearable inertial sensors for human movement analysis. **Expert Review of Medical Devices**, Taylor & Francis, v. 13, n. 7, p. 641–659, 2016. PMID: 27309490. DOI: [10.1080/17434440.2016.1198694](https://doi.org/10.1080/17434440.2016.1198694).

JAIN, Abhay. A smart gym framework: Theoretical approach. **2015 IEEE International Symposium on Nanoelectronic and Information Systems**, p. 191–196, 2015.

KANAL, Laveen N. Perceptron. In: **ENCYCLOPEDIA of Computer Science**. GBR: John Wiley e Sons Ltd., 2003. p. 1383–1385. ISBN 0470864125.

KARANDIKAR, Apurva et al. IoT based Smart Fitness Tracker for Gymnasiums. **International Research Journal of Engineering and Technology**, International Research Journal of Engineering e Technology, v. 6, n. 11, p. 2189–2192, nov. 2019.

KARVITZ, L. Exercise Motivation: What Starts and Keeps People Exercising. **University of New Mexico**, 2011.

KASSAB, Wafa'a; DARABKH, Khalid A. A–Z survey of Internet of Things: Architectures, protocols, applications, recent advances, future directions and recommendations. **Journal of Network and Computer Applications**, v. 163, p. 102663, 2020. ISSN 1084-8045.

KENNEY, W. Larry; WILMORE, Jack H.; COSTILL, David L. **Fisiologia do Esporte e do Exercício**. Tradução: Fernando Gomes do Nascimento. 7. ed. Barueri, São Paulo: Manole, abr. 2020. 704 p.

LARA, Oscar D.; LABRADOR, Miguel A. A Survey on Human Activity Recognition using Wearable Sensors. **IEEE Communications Surveys & Tutorials**, v. 15, n. 3, p. 1192–1209, 2013. ISSN 1553-877X.

MACHADO, Raoni Perrucci Toledo. **Esporte e religião no imaginário da Grécia Antiga**. São Paulo: Escola de Educação Física e Esporte, 2006. DOI: [10.11606/D.39.2006.tde-14032007-100902](https://doi.org/10.11606/D.39.2006.tde-14032007-100902).

MAGRANI, Eduardo. **A internet das coisas**. Rio de Janeiro: Editora FGV, 2018.

MAZIDI, Muhammad Ali; NAIMI, Sarmad; NAIMI, Sepehr. **AVR Microcontroller and Embedded Systems: Using Assembly and C (Pearson Custom Electronics Technology)**. Paperback. New York: Pearson, jan. 2010. p. 792. ISBN 978-0138003319.

MILMANN, KJ; AVAIZIS, M. Scientific Python, volume 11 of computing in science & engineering. **IEEE/AIP, March**, 2011.

MORTON, Lee; BAILLIE, Lynne; RAMIREZ-INIGUEZ, Roberto. Pose calibrations for inertial sensors in rehabilitation applications. **2013 IEEE 9th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)**, p. 204–211, out. 2013. ISSN 2160-4894. DOI: [10.1109/WiMOB.2013.6673362](https://doi.org/10.1109/WiMOB.2013.6673362).

MOTA, Felipe Augusto Oliveira. **Aplicação de rede de sensores sem fio para a análise do movimento humano**. Jul. 2017. Diss. (Mestrado).

NASCIMENTO, Alexandre; NASCIMENTO, Gabriel Sena. Associação entre atividade física e religião: da origem à atualidade. **UNITAS-Revista Eletrônica de Teologia e Ciências das Religiões**, v. 7, n. 2, p. 81–91, 2019.

NAVADA, Arundhati et al. Overview of use of decision tree algorithms in machine learning. **2011 IEEE Control and System Graduate Research Colloquium**, p. 37–42, 2011. DOI: [10.1109/ICSGRC.2011.5991826](https://doi.org/10.1109/ICSGRC.2011.5991826).

NODEMCU. **NodeMCU Documentation**. Disponível em: <<https://nodemcu.readthedocs.io/en/release/>>. Acesso em: 10 jan. 2021.

NORIEGA, Leonardo. Multilayer perceptron tutorial. **School of Computing, Staffordshire University**, Citeseer, v. 4, p. 5, 2005.

NYENHUIS, Sharmilee M. et al. Exercise and Fitness in the age of social distancing during the COVID-19 Pandemic. **The Journal of Allergy and Clinical Immunology: In Practice**, Elsevier, 2020.

OLIVEIRA, Sérgio de. **Internet das Coisas com ESP8266, Arduino e Raspberry Pi**. São Paulo: Novatec, 2017. ISBN 978-8575225813.

OLIVER, Nuria; FLORES-MANGAS, Fernando. MPTrain: A Mobile, Music and Physiology-Based Personal Trainer. Association for Computing Machinery, Helsinki, Finland, p. 21–28, 2006. DOI: [10.1145/1152215.1152221](https://doi.org/10.1145/1152215.1152221).

PEDREGOSA, Fabian et al. Scikit-learn: Machine learning in Python. **the Journal of machine Learning research**, JMLR. org, v. 12, p. 2825–2830, 2011.

PEDUZZI, Luiz Orlando de Q; PEDUZZI, Sonia Silveira. Física básica A. **Florianópolis: UFSC/EAD/CED/CFM**, v. 1, 2006.

PINTO, Gabriel; ROSA, Renata; RODRÍGUEZ, Demostenes. Applications for 5G Networks. **INFOCOMP Journal of Computer Science**, v. 20, n. 1, jun. 2021.

PODDAR, Shashi; KUMAR, Vipin; KUMAR, Amod. A Comprehensive Overview of Inertial Sensor Calibration Techniques. **Journal of Dynamic Systems, Measurement, and Control**, v. 139, n. 1, set. 2016. 011006. ISSN 0022-0434. DOI: [10.1115/1.4034419](https://doi.org/10.1115/1.4034419).

PORTELA, Joana Paula. **Cinesiologia**. 1. ed. Sobral, Ceará: INTA, 2016.

PROCESSING FOUNDATION. **Processing, an overview**. en. Set. 2022. Disponível em: <<https://processing.org/overview>>. Acesso em: 12 fev. 2023.

RABBI, Fazlay et al. When virtual reality meets Internet of things in the gym: enabling immersive interactive machine exercises. **Proceedings of the ACM on interactive, mobile, wearable and ubiquitous technologies**, ACM New York, NY, USA, v. 2, n. 2, p. 1–21, 2018.

RAINERIE, Angelo; KELLERMANN, Jan J. **Selected Topics In Preventive Cardiology**. 1. ed. New York: Springer, set. 1983. ISBN 9781461337386.

RAMOS, Jayr Jordão. **Exercícios físicos na história e na arte**. São Paulo: Ibrasa, 1983. v. 20.

RASCHKA, Sebastian. STAT 479: Machine Learning Lecture Notes. **University of Wisconsin, Department of Statistics**, p. 1–23, 2018.

ROLLAND, Yves; ABELLAN VAN KAN, Gabor; VELLAS, Bruno. Physical Activity and Alzheimer's Disease: From Prevention to Therapeutic Perspectives. **Journal of the American Medical Directors Association**, v. 9, n. 6, p. 390–405, 2008. ISSN 1525-8610.

ROUTH, K.; PAL, T. A survey on technological, business and societal aspects of Internet of Things by Q3, 2017. **2018 3rd International Conference On Internet of Things: Smart Innovation and Usages (IoT-SIU)**, p. 1–4, 2018.

SAFONOV, Alexander. **Prós e contras da arquitetura de rede neural**. pt. Nov. 2022. Disponível em: <<https://merehead.com/pt/blog/pros-contras-arquitetura-rede-neural/>>. Acesso em: 10 fev. 2023.

SANTOS, Bruno P. et al. Internet das coisas: da teoria à prática. **Minicursos SBRC-Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos**, v. 31, 2016.

SCIKIT LEARN. **Decision Trees**. en. Fev. 2023. Disponível em: <<https://scikit-learn.org/stable/modules/tree.html>>. Acesso em: 10 fev. 2023.

SCIKIT LEARN. **Getting Start**. en. Disponível em: <https://scikit-learn.org/stable/getting_started.html>. Acesso em: 10 fev. 2023.

SCIKIT LEARN. **Nearest Neighbors**. en. Disponível em: <<https://scikit-learn.org/stable/modules/neighbors.html#nearest-neighbors>>. Acesso em: 10 fev. 2023.

SCIKIT LEARN. **Neural network models (supervised): Multi-layer Perceptron**. en. Disponível em: <https://scikit-learn.org/stable/modules/neural_networks_supervised.html#neural-networks-supervised>. Acesso em: 10 fev. 2023.

SEARS, Francis et al. **Sears & Zemansky física I: mecânica**. São Paulo: Universidade de São Paulo, 2008.

SHIBATA, Takashi. Head mounted display. **Displays**, v. 23, n. 1, p. 57–64, 2002. ISSN 0141-9382. DOI: [https://doi.org/10.1016/S0141-9382\(02\)00010-0](https://doi.org/10.1016/S0141-9382(02)00010-0).

SILVA, Fernando Ginez da; GALEAZZO, Elisabete. Accelerometer based intelligent system for human movement recognition. **5th IEEE International Workshop on Advances in Sensors and Interfaces IWASI**, p. 20–24, jun. 2013. DOI: [10.1109/IWASI.2013.6576063](https://doi.org/10.1109/IWASI.2013.6576063).

SILVERTHORN, Dee Unglaub. **Fisiologia humana: uma abordagem integrada**. Edição: Leticia Bispo de Lima e Simone de Fraga. 7. ed. Porto Alegre: Artmed, 2017. 930 p.

STANČIN, Sara; TOMAŽIČ, Sašo. On the interpretation of 3D gyroscope measurements. **Journal of Sensors**, Hindawi, v. 2018, 2018.

SYSTEM 76. **Welcome to Pop!_OS**. en. 2023. Disponível em: [<https://pop.system76.com/>](https://pop.system76.com/). Acesso em: 11 fev. 2023.

TEDESCO, Kennedy. **Uma introdução a TCP, UDP e Sockets**. Jul. 2019. Disponível em: <https://www.treinaweb.com.br/blog/uma-introducao-a-tcp-udp-e-sockets>. Acesso em: 11 fev. 2023.

TIOBE. **TIOBE Index: The Python Programming Language**. en. Fev. 2023. Disponível em: <https://www.tiobe.com/tiobe-index/python/>. Acesso em: 1 fev. 2023.

VISHKAIE, Rojin. The Role of Wearable Technology in Children’s Creativity. **2018 International Conference on Cyberworlds (CW)**, p. 443–446, out. 2018. DOI: [10.1109/CW.2018.00087](https://doi.org/10.1109/CW.2018.00087).

WAKITA, A. et al. A coordination model for wearable fashion. **Ninth IEEE International Symposium on Wearable Computers (ISWC’05)**, p. 216–217, 2005. DOI: [10.1109/ISWC.2005.2](https://doi.org/10.1109/ISWC.2005.2).

WANG, Jianxin et al. The evolution of the Internet of Things (IoT) over the past 20 years. **Computers & Industrial Engineering**, Elsevier, v. 155, p. 107174, 2021.













WHITE, Rhiannon Lee et al. Domain-specific physical activity and mental health: a meta-analysis. **American Journal of Preventive Medicine**, v. 52, n. 5, p. 653–666, 2017.

WORLD HEALTH ORGANIZATION. **Physical Activity**. en. Fev. 2018. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/physical-activity>. Acesso em: 14 ago. 2020.

XING, Wenchao; BEI, Yilin. Medical Health Big Data Classification Based on KNN Classification Algorithm. **IEEE Access**, v. 8, p. 28808–28819, 2020. DOI: [10.1109/ACCESS.2019.2955754](https://doi.org/10.1109/ACCESS.2019.2955754).

ZURITA, Marcos EPV. Projeto de sistemas embarcados. **Universidade Federal do Piauí, Curso de Engenharia Elétrica, Campus Universitário Ministro Petrônio Portela**, 2011.

APÊNDICE A: Processamento e filtragem de conjunto amostral de rosca direta



APÊNDICE B: Processamento e filtragem de conjunto amostral de desenvolvimento de ombros

