



UNIVERSIDADE FEDERAL DO AMAZONAS - UFAM
INSTITUTO DE COMPUTAÇÃO - ICOMP
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA - PPGI

Um método para monitoramento e geração de feedbacks
em atividades físicas repetitivas baseado em Máquinas de
Boltzmann Restritas

Márcio André da Costa Alencar, M.Sc.

MANAUS-AM

2023



PODER EXECUTIVO
MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO AMAZONAS
INSTITUTO DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM
INFORMÁTICA



Um método para monitoramento e geração de feedbacks em
atividades físicas repetitivas baseado em Máquinas de Boltzmann
Restritas

Márcio André da Costa Alencar, M.Sc.

Tese apresentada ao Programa de Pós-Graduação em Informática, da Universidade Federal do Amazonas, como parte dos requisitos necessários à obtenção do título de Doutor em Informática, na área de concentração em Sistemas Embarcados e Engenharia de Softwares.

Orientador: Raimundo da Silva Barreto, D.Sc.

MANAUS-AM

2023

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

A368m Alencar, Márcio André da Costa
Um método para monitoramento e geração de feedbacks em atividades físicas repetitivas baseado em Máquinas de Boltzmann Restritas / Márcio André da Costa Alencar . 2023
103 f.: il. color; 31 cm.

Orientador: Raimundo da Silva Barreto
Tese (Doutorado em Informática) - Universidade Federal do Amazonas.

1. Máquinas de Boltzmann Restritas. 2. Reconhecimento de atividades. 3. Sensor inercial. 4. Atividades físicas repetitivas. I. Barreto, Raimundo da Silva. II. Universidade Federal do Amazonas III. Título



Ministério da Educação
Universidade Federal do Amazonas
Coordenação do Programa de Pós-Graduação em Informática

FOLHA DE APROVAÇÃO

"UM MÉTODO PARA MONITORAMENTO E GERAÇÃO DE FEEDBACKS EM ATIVIDADES FÍSICAS REPETITIVAS BASEADO EM MÁQUINAS DE BOLTZMANN RESTRITAS"

MÁRCIO ANDRÉ DA COSTA ALENCAR

Tese de Doutorado defendida e aprovada pela banca examinadora constituída pelos Professores:

Prof. Dr. Raimundo da Silva Barreto - PRESIDENTE

Prof. Dr. Moisés Gomes de Carvalho - MEMBRO EXTERNO

Prof. Dr. Mateus Rossato - MEMBRO EXTERNO

Prof. Dr. Paulo Romero Martins Maciel - MEMBRO EXTERNO

Dr. Walter Charles Sousa Seiffert Simões - MEMBRO EXTERNO

Manaus, 18 de dezembro de 2023



Documento assinado eletronicamente por **Raimundo da Silva Barreto, Professor do Magistério Superior**, em 22/12/2023, às 14:53, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Mateus Rossato, Professor do Magistério Superior**, em 09/01/2024, às 09:16, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de](#)

[outubro de 2015.](#)



Documento assinado eletronicamente por **Moisés Gomes de Carvalho, Professor do Magistério Superior**, em 09/01/2024, às 15:40, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **Walter Charles Sousa Seiffert Simões, Usuário Externo**, em 19/01/2024, às 14:58, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **Paulo Romero Martins Maciel, Usuário Externo**, em 26/02/2024, às 17:07, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



A autenticidade deste documento pode ser conferida no site https://sei.ufam.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1817971** e o código CRC **7CEA152C**.

Avenida General Rodrigo Octávio, 6200 - Bairro Coroado I Campus Universitário
Senador Arthur Virgílio Filho, Setor Norte - Telefone: (92) 3305-1181 / Ramal 1193
CEP 69080-900, Manaus/AM, coordenadorppgi@icomp.ufam.edu.br

Referência: Processo nº 23105.051489/2023-18

SEI nº 1817971

Aos que acreditam na Ciência.

Agradecimentos

Num momento em que tantas pessoas enfrentaram a perda de amigos, familiares, colegas de pesquisa e professores, sinto-me profundamente tocado e grato por Deus, cuja misericórdia infinita nos envolve diariamente durante esses intensos quatro anos de jornada. Não foi apenas uma caminhada acadêmica desafiadora, mas também emocionalmente exigente. Em uma era em que a validade da Ciência é questionada por muitos, é nossa responsabilidade resistir e persistir em seu progresso.

Nesse contexto, quero expressar minha gratidão às pessoas que estiveram ao meu lado diariamente. A minha amada esposa, Carol Falcão, dedicou inúmeras horas de trabalho árduo, proporcionando-me o espaço necessário para avançar em minha pesquisa. O mesmo se aplica a Maria Sofia, minha filha mais velha, que, apesar de toda a empolgação e energia próprias de sua idade, demonstra ser uma menina comportada e prestativa, sempre disposta a ajudar. A Ana Cecília e Aysah Luanny são as outras duas preciosidades que completam meu jardim.

Destaco, com imensa gratidão, a participação fundamental do meu orientador, Prof. Dr. Raimundo Barreto, que tem estado ao meu lado desde 2017, oferecendo todo o suporte acadêmico e, em muitas ocasiões, desempenhando o papel de psicólogo e amigo. Sua paciência aparentemente infinita permite que eu compartilhe minhas ideias mais absurdas, sendo acatadas ou rejeitadas com o mesmo carisma, educação e classe que lhe são característicos. Agradeço também aos demais familiares que me incentivaram e apoiaram ao longo dessa árdua jornada. Sem o apoio de todos vocês, eu não teria chegado até aqui. Muito obrigado!

Esta pesquisa foi financiada parcialmente pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior—Brasil (CAPES-PROEX)—Código 001, também pela Fundação de Amparo à Pesquisa do estado do Amazonas—FAPEAM, através do projeto POSGRAD

2022-2023, e também, de acordo com o Artigo 48 do Decreto nº 6.008/2006, pela Samsung Electronics of Amazonia Ltda, sob os termos da Lei Federal nº 8.387/1991, através do arcordo nº 003/2019, assinado com o IComp/UFAM.

*"Descobrir consiste em olhar para o que
todo mundo está vendo e pensar uma coisa
diferente."*

(Albert Szent-Györgyi)

Resumo

A prática de atividades físicas, muitas vezes realizadas em ambientes como academias e sessões de fisioterapia, exige a execução precisa dos movimentos para garantir resultados eficazes e evitar lesões. Atualmente, abordagens que combinam tecnologias vestíveis e Inteligência Artificial (IA) são empregadas para identificar a correta execução dos movimentos. No entanto, essas abordagens têm limitações, pois estão vinculadas a atividades físicas pré-programadas e não fornecem orientações específicas para corrigir os movimentos. Esta tese propõe uma abordagem disruptiva para gerar modelos em tempo de execução capazes de oferecer sugestões de ajustes aos usuários, visando a correta execução do movimento. Utilizando dados de sensores inerciais, como acelerômetro e giroscópio, a abordagem monitora, aprende padrões, analisa e fornece sugestões de correções para os dados inerciais de cada segmento corporal, por meio de uma Máquina de Boltzmann Restrita. Os resultados demonstram que a geração desses modelos em tempo de execução, capaz de se adaptar a diferentes biotipos e limitações dos usuários, é eficiente na produção de orientações de ajustes nos movimentos, resultando em uma semelhança até 3,68 vezes maior com o movimento correto. Isso valida a eficácia do método proposto para seu propósito.

Palavras-chave: Máquinas de Boltzmann Restrita; Reconhecimento de atividades; Sensor inercial; Atividade física repetitiva.

Abstract

The practice of physical activities, often carried out in environments such as gyms and physiotherapy sessions, requires precise execution of movements to ensure effective results and prevent injuries. Currently, approaches that combine wearable technologies and Artificial Intelligence (AI) are employed to identify the correct execution of movements. However, these approaches have limitations as they are tied to pre-programmed physical activities and do not provide specific guidance to correct movements. This thesis proposes a disruptive approach to generate execution-time models capable of offering adjustment suggestions to users, aiming for the correct execution of movements. Using data from inertial sensors, such as accelerometers and gyroscopes, the approach monitors, learns patterns, analyzes, and provides correction suggestions for the inertial data of each body segment through a Restricted Boltzmann Machine. The results demonstrate that the generation of these execution-time models, adaptable to different body types and user limitations, is efficient in producing adjustment guidance for movements, resulting in a similarity up to 3.68 times greater with the correct movement. This validates the effectiveness of the proposed method for its purpose.

Keywords: Restricted Boltzmann Machine; Human Activity Recognition; Inertial Measurement Units; Repetitive Physical Activity.

Lista de Figuras

2.1	MEMs observados em microscópio.	25
2.2	Orientação dos eixos dos sensores. (<i>IMU Axis References 2021</i>)	26
2.3	Conversão de valores brutos (a) de um acelerômetro e de um giroscópio para magnitudes (b).	27
2.4	Comparação entre Distância Euclidiana e DTW para análise de similaridades em séries temporais. (Tavenard 2021)	29
2.5	Caminho do alinhamento apresentado em forma de matriz.(Tavenard 2021) .	30
2.6	Representação gráfica de uma Máquina de Boltzmann com 4 nós visíveis ($v_1\dots v_4$) e 3 nós ocultos ($h_1\dots h_3$).	33
2.7	Representação gráfica de uma Máquina de Boltzmann Restrita com 4 nós visíveis ($v_1\dots v_4$) e 3 nós ocultos ($h_1\dots h_3$).	35
3.1	Principais posicionamentos dos sensores no corpo.	43
4.1	<i>Pipeline</i> de treinamento do modelo.	63
4.2	<i>Pipeline</i> de aplicação do modelo treinado para análise de novas entradas. . .	64
4.3	Iterações de decremento do limiar para identificação dos centroides em cada amostra ao longo da série temporal.	65
4.4	Amostras obtidas após o processo de seleção automatizada.	66
4.5	Etapas para binarização, geração das recomendações e reconstrução da série temporal.	68
5.1	Exemplos de dados de magnitude para: (a) Treinamento; (b) Validação; (c) e (d) Testes	72

5.2	Fluxograma de avaliação do método proposto	73
5.3	Amostras extraídas da série temporal de treinamento da Figura 5.1 a.	75
5.4	Matriz de distâncias entre amostras e distância média de amostra para as demais (AVG).	75
5.5	Distância média para a série de referência por modelo e segmento do corpo. .	76
5.6	Centroides identificados em uma série com menos repetições que o esperado .	77
5.7	Exemplo de ganho negativo ($G < 0$): Comparação da Série de Referência em relação às séries: (a) Entrada, (b) Saída RBM e (c) Saída RBM+DTW. . . .	78
5.8	Exemplo de ganho positivo ($G > 0$): Comparação da Série de Referência em relação às séries: (a) Entrada, (b) Saída RBM e (c) Saída RBM+DTW. . . .	79
5.9	Ganho médio por modelo e segmento.	79
5.10	Teste: Distância média por modelo para cada segmento.	80
5.11	Teste: Ganho médio por modelo para cada segmento.	81
5.12	Testes: Comparação da Série de Referência em relação às séries: (a) Entrada, (b) Saída RBM e (c) Saída RBM+DTW.	82
5.13	Testes: Ganho médio dos modelos para cada exercício por segmento.	82

Lista de Tabelas

2.1	Matriz de custos para a séries x e x'	31
2.2	Caminho do alinhamento de menor custo.	32
3.1	Sensores presentes nos dispositivos identificados.	39
3.2	Limites suportados pelos sensores em cada componente inercial encontrado.	40
3.3	Relação de estudos por posição dos sensores.	44
3.4	Atributos sobre voluntários, sensores e escopos de atividades.	47
3.5	Trabalhos Relacionados	59

Lista de Abreviaturas e Siglas

AC	<i>Análise de Caminhada</i>
AD	<i>Atividades Diárias</i>
AE	<i>Atividades Esportivas</i>
AF	<i>Atividades Físicas</i>
AVG	<i>Average</i>
DE	<i>Distância Euclideana</i>
DOF	<i>Degree of Freedom</i>
DQ	<i>Detecção de Quedas</i>
DTW	<i>Dynamic Time Warping</i>
EAH	<i>Extenção dos braços acima da cabeça</i>
EFE	<i>Flexão/Extensão do Cotovelo</i>
IMUs	<i>Inertial Measurement Units</i>
KFE	<i>Flexão/Extensão de Joelhos</i>
MEMS	<i>Microelectromechanical Systems</i>
N/D	<i>Não Disponível / Não Documentado</i>
N/E	<i>Não Especificado</i>
RBM	<i>Restricted Boltzmann Machines</i>
RG	<i>Reconhecimento de Gestos</i>
SQT	<i>Agachamento</i>
SQZ	<i>Apertar/Espremer/Torcer com as mãos</i>
SR	<i>Série de Referência</i>

Lista de Símbolos

#	Número (#1 = Número um)
Ω	Velocidade angular
Σ	Somatório
\in	Pertence
\notin	Não Pertence
$<$	Menor que
\leq	Menor ou igual a
$>$	Maior que
\geq	Maior ou igual a
π	Caminho do alinhamento
$ x $	Valor absoluto de x (positivo)
∂x	Derivada parcial de x
$\langle x, y \rangle$	Valor esperado para a aresta que une os nós x e y
$^\circ/s$	Graus radianos por segundo
$\mu\mathbf{T}$	Unidade de medida de campo magnetico (microTesla)
cm	Centímetros
g	Aceleração da gravidade da terra (m/s^2)
G	Métrica ganho
Hz	Medida de frequência (ciclos em um segundo)
K	Número de elementos no caminho do alinhamento
Kg	Quilogramas
$\min(x, y)$	Menor valor entre x e y
$\text{prob}(x = 1)$	Probabilidade de x ser igual a 1

Sumário

1	Introdução	19
1.1	Motivação	20
1.2	Definição do problema	21
1.3	Objetivos	21
1.4	Hipótese	22
1.5	Organização do trabalho	22
2	Fundamentação Teórica	24
2.1	Sensores Inerciais	24
2.2	Métrica Magnitude	26
2.3	Sincronização Temporal Dinâmica	28
2.4	Máquinas de Boltzmann	33
2.4.1	Máquina de Boltzmann Restrita	35
2.4.2	Processo de aprendizagem nas Máquinas de Boltzmann	36
2.5	Resumo	36
3	Trabalhos Correlatos	37
3.1	Bases de dados públicas baseadas em sensores inerciais	37
3.1.1	<i>Hardware</i> s	38
3.1.2	Pontos de Monitoramento	41
3.1.3	Escopos de Monitoramento	45
3.1.4	Revisão das bases de dados	46
3.2	Monitoramento de Atividades Físicas	55

3.3	Resumo	61
4	Método Proposto	62
4.1	Visão geral	62
4.2	Seleção automatizada de amostras	64
4.3	Binarização de Séries Temporais	67
4.4	Geração das recomendações	68
4.5	Resumo	70
5	Avaliação do Método Proposto	71
5.1	Método de avaliação	71
5.2	Resultados	74
5.2.1	Obtenção da série de referência	74
5.2.2	Resultados da Validação	76
5.2.3	Resultados dos Testes	80
5.2.4	Discussão	83
5.2.5	Resumo	85
6	Conclusão	86
6.1	Contribuições	86
6.2	Limitações	88
6.3	Considerações Finais	89
6.4	Trabalhos futuros	90
	Referências Bibliográficas	92

Capítulo 1

Introdução

Originalmente identificada como um problema típico de reconhecimento de padrões, e mais especificamente, um problema de classificação (Lima *et al.* 2021), a geração de modelos preditivos, realizadas através de redes neurais artificiais, fazem uso de um grande volume de dados para a identificação de padrões entre amostras similares, permitindo classificá-las/agrupá-las sob um mesmo rótulo, ou classe, que as representem. Os resultados das aplicações desta tecnologia em áreas como automação residencial (Shi *et al.* 2022; Perumal *et al.* 2023; Manimaran *et al.* 2023), linguagens de sinais (Zhang *et al.* 2023; Nadaf e Pardeshi 2023; Wang *et al.* 2022), análise de caminhada (Kiprijanovska *et al.* 2023; Tao *et al.* 2023; Seo 2023), detecção de quedas (Huang e Clancy 2022; Kim *et al.* 2023; Sherin Zebiah *et al.* 2023), e otimização de desempenho de atletas (Freire-Obregón *et al.* 2023; VanBibber *et al.* 2023; Zhou *et al.* 2023) deixam evidente a importância de seu estudo.

No escopo de monitoramento de atividades físicas repetitivas, que geralmente são executadas em academias e sessões de fisioterapia, os modelos são produzidos a fim de reconhecer qual atividade física o usuário está realizando. Os modelos são treinados através da análise de dados que mapeiam todos os movimentos associados às várias atividades físicas realizadas por pessoas distintas. Ao final, um modelo genérico é criado capaz de reconhecer a atividade em execução, caso o usuário realize um dos movimentos mapeados no treinamento. Estes modelos são de difíceis adaptações, uma vez que a inclusão de novas classes (atividades físicas) exige a coleta de dados e/ou o retreinamento do modelo, consumindo mais tempo e recursos para sua atualização.

Outro fator importante é a carência de modelos que forneçam orientações aos usuários para a execução apropriada dos exercícios físicos. Se por um lado há vários modelos que identificam de forma eficiente o tipo de movimento executado, por outro, a generalização do reconhecimento de padrões impossibilita a geração de orientações detalhadas para ajustar o movimento de forma a corrigi-lo. As possíveis variações de biótipos corporais entre os usuários demandam um número elevado de modelos distintos, inviabilizando uma aplicação real devido à complexidade de manutenção destes. Além disso, o uso de modelos inadequados que se adaptam parcialmente às capacidades dos usuários podem levar a sobrecarga da musculatura e, conseqüentemente, possíveis lesões (ósseas, musculares, articulares, conjuntivas).

Nesse sentido, esta Tese apresenta uma alternativa que visa contornar os três principais desafios encontrados para a produção de modelos usados no monitoramento de atividades físicas repetitivas: (i) produção de modelos de forma dinâmica em tempo de execução; (ii) avaliação qualitativa do movimento executado; e (iii) produção de orientações úteis aos usuários para ajustes dos movimentos executados.

1.1 Motivação

Além de mitigar problemas de re-treinamento de modelos para adição de novas classes, ao encontrar uma alternativa para os desafios apresentados, será possível desenvolver uma tecnologia para auxiliar os usuários na execução de seus movimentos durante a prática de atividade física repetitiva. Esta tecnologia poderá auxiliar não só aos usuários, mas também aos profissionais que poderão dar um suporte mais eficiente a múltiplos usuários simultaneamente. Além disso, o desenvolvimento de uma aplicação para o mercado *fitness* poderá mudar drasticamente a relevância dos dispositivos vestíveis/redes neurais, de uma simples tecnologia de monitoramento para uma abordagem disruptiva que melhora o desempenho dos usuários e previne lesões.

1.2 Definição do problema

O processo de treinamento de modelos de reconhecimento em redes neurais artificiais tem um custo computacional elevado devido à quantidade de amostras que devem ser analisadas para que o modelo identifique o padrão e, posteriormente, alcance taxas de acertos satisfatórias. Tal custo se estende a recursos como tempo, armazenamento e processamento, sendo fatores relevantes para a implementação de soluções que fazem uso desta metodologia. Além disso, em ambientes como academias, a variação na quantidade de movimentos que devem ser reconhecidos e a qualidade da execução de cada um são fatores relevantes para os usuários.

Nesse cenário, esta Tese busca responder ao seguinte questionamento: *É possível fornecer um modelo de aprendizado de máquina capaz de gerar sugestões aos usuários durante a execução de exercícios físicos que os ajudem a melhorar seus movimentos, evitando generalizações que não são adequadas à biótipo corporal do usuário?* Em poucas palavras, *como podemos propor uma abordagem para gerar modelos específicos para atender cada usuário com base em suas características físicas?*

1.3 Objetivos

O objetivo principal desta Tese é propor, validar e testar, um método capaz de produzir modelos que aprendam os padrões inerciais produzidos durante uma atividade física repetitiva e forneçam aos usuários sugestões de ajustes no movimento que permitam sua execução adequada.

Para que tal objetivo seja alcançado, faz-se necessário o cumprimento dos seguintes objetivos específicos.

- Propor e validar um método para seleção automatizada de amostras de dados, produzidos por sensores inerciais, a partir de uma série temporal contínua não rotulada.
- Integrar o método de seleção automatizada ao processo de treinamento redes neurais artificiais para a produção dinâmica dos modelos de sugestão.
- Fornecer aos usuários, em tempo de execução, *sugestões* descritivas para ajustes de movimentos quando necessários.

- Testar o método proposto através de experimentos em bases de dados públicas de atividades físicas repetitivas permitindo identificar o ganho de aplicar as sugestões geradas pelo modelo à exercícios executados incorretamente.

1.4 Hipótese

Em ambientes como academias e espaços de reabilitação e fisioterapia, a execução de movimentos repetitivos deve ser assistida por um profissional qualificado para garantir a eficiência dos exercícios. Com a prática na execução dos exercícios, os indivíduos tendem a melhorar seus desempenhos, alterando o ritmo, amplitude de movimento, frequências de repetições e outros fatores biomecânicos que podem interferir na capacidade de modelos pré-treinados em reconhecer os movimentos executados.

Neste cenário, levantou-se a hipótese de que a avaliação dos segmentos corporais de forma individual possibilitaria a geração de modelos de reconhecimentos de movimentos mais precisos usando poucas amostras de alta qualidade durante o processo de treinamento. Além disso, esta análise mitiga a geração de ruídos provocados por sensores adjacentes, reduzindo a complexidade de identificação de padrões nos dados produzidos.

Finalmente, complementando a hipótese, o retreinamento de modelos ao início da execução de cada atividade física, possibilitaria a atualização de modelo de reconhecimento, contornando problemas como deslocamento de sensores e adaptação do perfil/capacidade do usuário em executar os movimentos ao longo da prática de atividades físicas.

1.5 Organização do trabalho

Para melhor compreensão desta proposta de tese, este documento está dividido em 6 capítulos que abordam desde a introdução ao tema até uma conclusão sucinta sobre a pesquisa executada.

O **Capítulo 1** introduz o leitor no contexto do tema abordado apresentando a definição do problema, os objetivos e a hipótese levantada por esta Tese. O **Capítulo 2** discorre sobre temas que capacitam o leitor a compreender o método proposto. Buscando avaliar o

estado da arte na área de estudo abordada o **Capítulo 3** apresenta trabalhos que buscam alternativas para o mesmo problema de pesquisa desta Tese, além de discorrer sobre bases de dados públicas, produzidas com auxílio de sensores inerciais com potencial para serem usadas como ferramenta de avaliação do método proposto. A descrição detalhada do método proposto por esta tese é apresentada no **Capítulo 4**, onde são apresentados os módulos e como estão relacionados entre si. No **Capítulo 5**, são apresentados o método empregado para avaliação desta tese e os resultados de experimentos. Por fim, são apresentadas as considerações finais no **Capítulo 6**.

Capítulo 2

Fundamentação Teórica

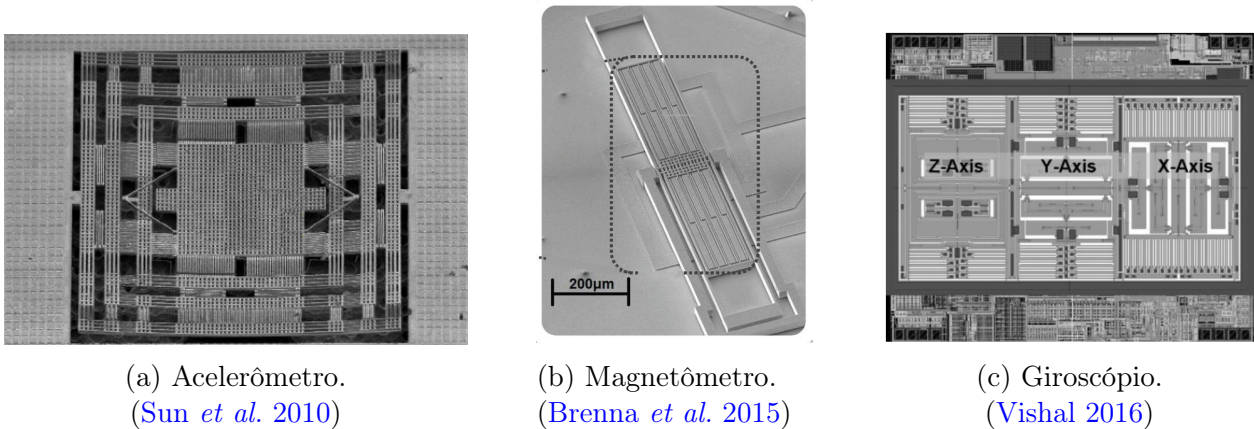
Para melhor compreensão dos elementos que compõem este estudo, faz-se necessário o entendimento prévio de alguns mecanismos, técnicas e tecnologias, como estas se adequam ao desenvolvimento dos experimentos e como corroboram para alcançar os objetivos desta pesquisa. Neste capítulo são introduzidos conceitos sobre Sensores Inerciais (Seção 2.1), descrevendo como funcionam e para que são utilizados, a métrica Magnitude (Seção 2.2) apresentando seu cálculo e sua relevância, *Dynamic Time Warping* (Seção 2.3), apontando suas características, funcionamento e exemplos de aplicação dessa técnica, além da Seção 2.4 a qual introduz o funcionamento das Máquinas de Boltzmann, em geral, e das Máquinas de Boltzmann Restrita, em particular.

2.1 Sensores Inerciais

Também conhecidos como Unidades de Medição Inercial (do inglês: *Inertial Measurement Units* - IMU), são componentes micro-eleto-mecânicos (MEMS) capazes de aferir diferentes aspectos inerciais a cerca de um objeto. Estes componentes combinam eletrônica e mecânica a uma escala micrométrica capazes de detectar os mais sensíveis movimentos.

A Figura 2.1 apresenta as observações em microscópio das estruturas eletromecânicas dos MEMS que fazem a medição para os três sensores abordados nesta tese: Acelerômetro (Figura 2.1a), Magnetômetro (Figura 2.1b) e Giroscópio (Figura 2.1c).

Os hardwares são compostos por estruturas mecânicas flexíveis que, ao serem es-



(a) Acelerômetro.
(Sun *et al.* 2010)

(b) Magnetômetro.
(Brenna *et al.* 2015)

(c) Giroscópio.
(Vishal 2016)

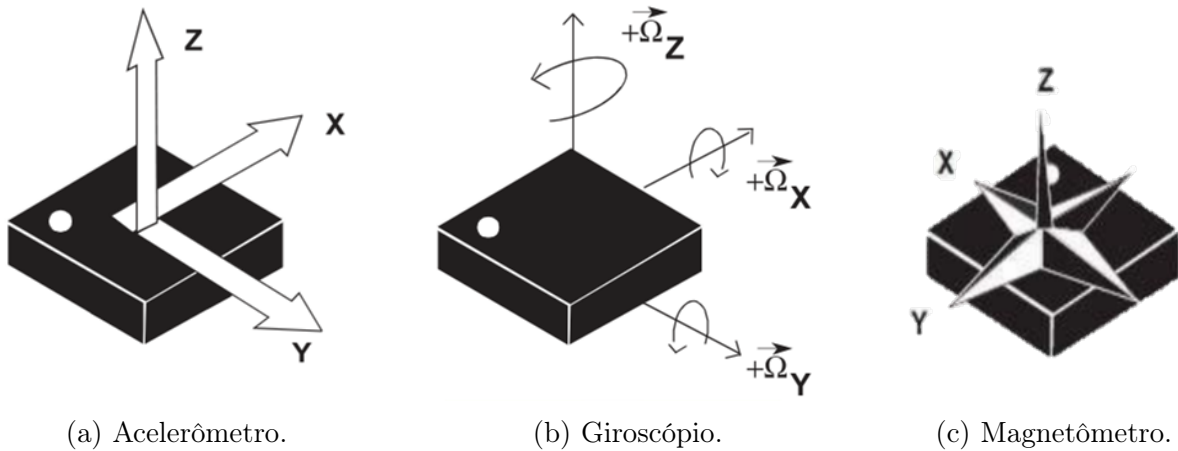
Figura 2.1: MEMs observados em microscópio.

timulados, ativam contatos eletrônicos que permitem mensurar a intensidade do estímulo realizado. Essa descrição em alto nível se aplica ao funcionamento dos três sensores (acelerômetro, giroscópio e magnetômetro), sendo os dois primeiros acionados através de estímulos mecânicos (vibrações/movimentos) e o terceiro por meio de campos magnéticos (terrestre, ímãs e eletroímãs).

Os sensores inerciais são componentes poderosos e de baixo custo que medem a aceleração linear (acelerômetro), a velocidade angular (giroscópio) e, eventualmente, a força magnética (magnetômetro) em três eixos diferentes (x , y e z). Cada eixo, também identificado como Grau de Liberdade (do inglês: *Degree of Freedom* - DOF), indica uma variável independente que provê seus próprios dados a partir das leituras dos sensores. Como exemplo, um IMU composto por um acelerômetro, magnetômetro e giroscópio possui 9 graus de liberdade (9-DOF), sendo monitorado três eixos em cada sensor (ver Figura 2.2).

Um acelerômetro (Figura 2.2a) é um sensor capaz de estimar a variação da velocidade em 3 direções diferentes (eixos x , y e z). Este sensor também pode oferecer indicações sobre inclinação, inclinação da borda, obliquidade, revolução, vibração e colisão (Khimraj *et al.* 2020). A unidade de medida destes sensores geralmente é dada em m/s^2 (metros por segundo ao quadrado).

A Figura 2.2c ilustra os eixos de leituras de um giroscópio. Diferente do acelerômetro, este sensor calcula a velocidade angular em cada eixo. Esta medida consiste em identificar a força aplicada para mover o sensor em torno de um eixo específico. O movimento de torção



(a) Acelerômetro.

(b) Giroscópio.

(c) Magnetômetro.

Figura 2.2: Orientação dos eixos dos sensores. (*IMU Axis References 2021*)

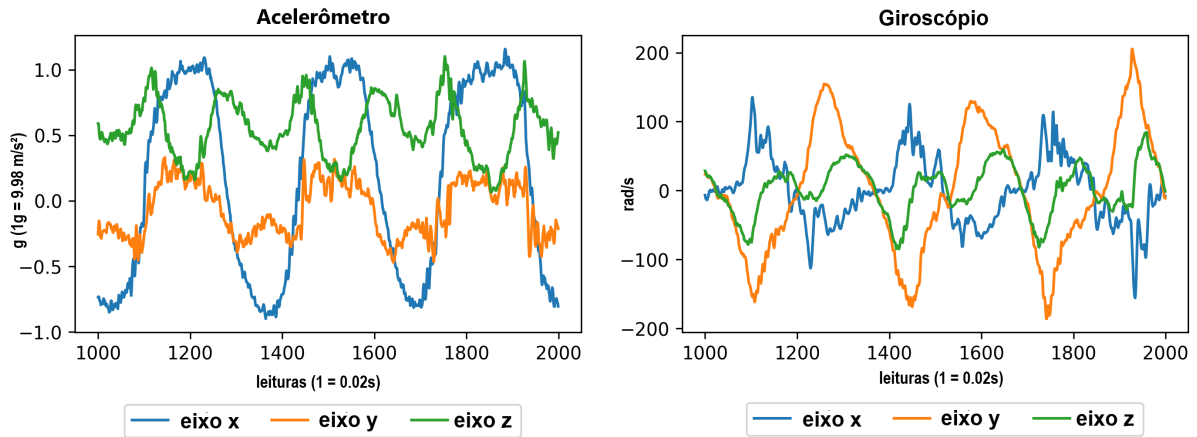
para o eixo x é identificado como rolagem (*roll*), para o eixo y é arfagem (*pitch*) e no eixo z é guinada (*yaw*). Sua unidade de medida é definida em rad/s (graus radianos por segundo).

Na Figura 2.2 temos a ilustração dos eixos de um magnetômetro, o qual é afetado por campos magnéticos, normalmente o da terra, e auxilia na calibração e otimização das leituras do acelerômetro e do giroscópio. Apesar de sua importância, nem todos os componentes inerciais possuem este sensor. A unidade de medida de suas leituras geralmente são feitas G (*gauss*) porém, alguns fabricantes também as apresentam em μT (*microtesla*) sendo $1G = 100\mu T$.

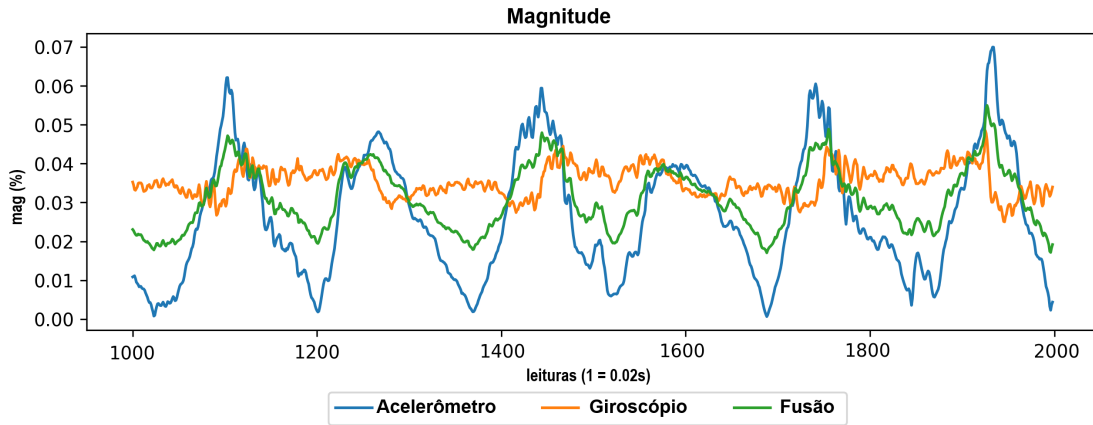
Apesar das unidades serem bem definidas para cada sensor, é importante destacar que cada componente possui um protocolo de comunicação e um formato de dados que são especificados no manual do fabricante. Além disso, a quantidade/tipo de dados podem variar de acordo com a sensibilidade definida para os sensores. Por isso, estes sensores podem gerar dados incorretos, caso a estímulo exercido durante o monitoramento seja superior aos limites suportados. Portanto, os sensores devem ser sempre estudados e configurados adequadamente.

2.2 Métrica Magnitude

Embora os módulos inerciais sejam capazes de aferir forças de sensores diferentes em cada eixo de forma individual, conforme ilustrado na Figura 2.3a, em alguns casos é importante que



(a) Amostra de dados brutos do Acelerômetro e do Giroscópio.



(b) Magnitude dos dados brutos do Acelerômetro, Giroscópio e a Fusão de ambas magnitudes.

Figura 2.3: Conversão de valores brutos (a) de um acelerômetro e de um giroscópio para magnitudes (b).

essas sejam combinadas permitindo a identificação dos valores absolutos da força imprimida sobre os sensores. Para tal, usa-se a métrica Magnitude.

A Magnitude (Shoib *et al.* 2014; Kwolek e Kepski 2014) de um sensor ($MSens$) é identificada pela soma das forças exercidas em um determinado sensor para todos os eixos. Tal soma é definida pela equação $MSens = \sqrt{x_i^2 + y_i^2 + z_i^2}$ onde a x, y e z são os valores obtidos pelo sensor ($Sens$) no instante i nos eixos x, y e z . Um exemplo desta conversão pode ser observada na Figura 2.3b.

Uma vantagem de usar a métrica magnitude é que seus valores são dados em módulos, ou seja, toda a série temporal que oscila entre valores negativos e positivos são convertidos para valores positivos. Isto permite identificar que, quando a série está em uma tendência

crecente, o sensor está sofrendo um movimento de aceleração e quando a série está em uma tendência decrescente, há uma desaceleração do movimento, além disso, com a magnitude, fica mais perceptível compreender o ciclo completo de um movimento repetitivo, que geralmente possui 4 etapas: (i) início/aceleração do movimento a partir da posição inicial; (ii) pausa/desaceleração no ápice do movimento (iii) reinício/aceleração à posição inicial; e (iv) pausa/desaceleração na posição inicial. Para um movimento repetitivo, este ciclo se repete constantemente, sendo essencial identificá-los claramente.

Individualmente, a série da magnitude do acelerômetro indica as acelerações e desacelerações que o sensor sofreu, já a magnitude do giroscópio indica a amplitude a qual esse sensor foi deslocado. A fusão de dados entre as magnitudes do acelerômetro e do giroscópio, permite a identificação de ambos comportamentos em uma só métrica. Esses dados são normalizados e representados entre 0 e 1 indicando o percentual do range para cada sensor. Esta fusão é dada pela equação $MFus_i = (0.5 \times MAcc_i) + (0.5 \times MGyr_i)$ sendo $MFus_i$ a fusão entre as leituras normalizadas de magnitudes do acelerômetro ($MAcc_i$) e do giroscópio ($MGyr_i$) ponderados igualmente no instante i . Tal fusão permite que a série temporal se porte de forma similar à modulação de sinais em radiodifusão, aumentando e reduzindo o comprimento e amplitude das ondas resultantes de acordo com o comportamento das ondas individuais.

É possível observar na Figura 2.3b (linha verde) que ao realizar a fusão balanceada entre as séries de magnitudes do acelerômetro e do giroscópio, foi possível gerar uma nova série temporal com padrões que destacam as nuances existentes nas séries individuais. Esse resultado permite identificar de forma mais clara grupos de movimentos que consistem em acelerações e desacelerações consecutivas, como é o exemplo de práticas de atividades físicas com movimentos repetitivos. Apesar de suas vantagens, o uso da magnitude inviabiliza o cálculo de ângulos e orientação dos movimentos executados.

2.3 Sincronização Temporal Dinâmica

Apresentada por Vintsyuk (1968) e Sakoe e Chiba (1978) para tratar problemas quanto ao reconhecimento de fala, esta técnica consiste em encontrar o melhor alinhamento entre duas

séries temporais com o intuito de compará-las para identificar a similaridade entre ambas.

A Sincronização Temporal Dinâmica (do inglês: *Dynamic Time Warping* - DTW) é uma abordagem mais eficiente para cálculo de similaridades entre séries temporais que a tradicional Distância Euclidiana (DE). Enquanto a segunda se limita a identificar a distância entre os pontos que pertencem ao mesmo índice de cada série (ver Figura 2.4a), o DTW busca encontrar o melhor alinhamento entre os pontos (ver Figura 2.4b), permitindo comparar séries similares com pequenas variações. A similaridade entre as duas séries é dada através do somatório das distâncias calculadas entre os pontos mapeados entre as duas séries. Nas imagens presentes na Figura 2.4, a distância entre os pontos são representadas pelas linhas cinzas que conectam os pontos de cada série.




Figura 2.4: Comparação entre Distância Euclidiana e DTW para análise de similaridades em séries temporais. (Tavenard 2021)

Sendo x e x' duas séries temporais pertencentes ao mesmo espaço dimensional q em que suas amostra x_i e x'_j tem sua ordem preservada independente do intervalo de tempo que ocorrem, é possível definir formalmente o problema de otimização com a seguinte equação:

$$DTW_q(x, x') = \min_{\pi \in A(x, x')} \left(\sum_{(i, j) \in \pi} d(x_i, x'_j)^q \right)^{\frac{1}{q}} \quad (2.1)$$

Sendo o alinhamento de menor custo entre x e x' dado por um caminho π (caminho do alinhamento) de tamanho K , pertencente ao conjunto de todos os caminhos admissíveis $A(x, x')$, o mesmo é representado por K tuplas (índices) no formato $((i_0, j_0) \dots (i_{K-1}, j_{K-1}))$. Para que um caminho seja considerável admissível e pertencer a $A(x, x')$, é necessários que

satisfaçam aos seguintes critérios: $\pi_0 = (0, 0)$ e $\pi_{K-1} = (n-1, m-1)$, onde $i_{k-1} \leq i_k \leq i_{k-1} + 1 \wedge j_{k-1} \leq j_k \leq j_{k-1} + 1$, ou seja, i e j incrementam monotonicamente exigindo que os índices de cada série apareça pelo menos uma única vez no caminho do alinhamento (π).

Esta definição pode ser mais facilmente entendida quando representada como notação do produto escalar onde o caminho DTW é dado por:

$$(A_\pi)_{i,j} = \begin{cases} 1 & \text{se } (i, j) \in \pi \\ 0 & \text{se } (i, j) \notin \pi \end{cases} \quad (2.2)$$

A Equação 2.2 pode ser visualmente interpretada como apresenta a Figura 2.5. Onde uma série x é representada como as linhas da tabela e a série x' compõem as colunas. As coordenadas da matriz não marcadas com 0 compõem o caminho mais curto entre os pontos e, conseqüentemente, o melhor alinhamento entre ambas as séries.




Figura 2.5: Caminho do alinhamento apresentado em forma de matriz. (Tavenard 2021)

A representação deste problema por meio da notação matricial pode ser formalmente escrita como a minimização de um produto escalar entre matrizes dada pela fórmula:

$$DTW_q(x, x') = \min_{\pi \in A(x, x')} \langle A_\pi, D_q(x, x') \rangle^{\frac{1}{q}} \quad (2.3)$$

Onde $D_q(x, x')$ armazena as distâncias $d(x, x')$ elevado à potência q . Como exemplo, para as séries $x = \{1, 4, 5, 10, 9, 3, 2, 6, 8, 4\}$ e $x' = \{1, 7, 3, 4, 1, 10, 5, 4, 7, 4\}$ é possível calcular os valores da matriz por meio da programação dinâmica seguindo a seguinte equação:

$$D_q(x_i, x'_j) = |x_i - x'_j| \min(D_q(x_{i-1}, x'_{j-1}), D(x_i, x'_{j-1}), D(x_{i-1}, x'_j)) \quad (2.4)$$

Onde $D_q(x_i, x'_j)$ é o elemento da matriz de custos D_q cujo valor é obtido através dos elementos na posição i de x e j de x' , sendo i e j interações das séries comparadas. A Tabela 2.1 ilustra uma tabela de custos entre as séries x e x' .

Tabela 2.1: Matriz de custos para a séries x e x' .

x_9	4	42	24	2	17	20	25	19	18	18	15*
x_8	8	39	21	19	17	20	19	18	15	15	18
x_7	6	32	20	15	13*	17	28	15	15	14	16
x_6	2	27	19	11	12	12	20	14	13	17	18
x x_5	3	26	14	10	11	13	16	11	12	16	17
x_4	9	24	10	14	16	19	9	12	17	18	21
x_3	10	16	8	12	11	14	8	13	18	16	21
x_2	5	7	5	5	5	8	12	12	13	15	16
x_1	4	3	3	4	4	7	13	14	14	17	17
x_0	1	0*	6	8	11	11	20	24	27	33	36
		1	7	3	4	1	10	5	4	7	4
		x'_0	x'_1	x'_2	x'_3	x'_4	x'_5	x'_6	x'_7	x'_8	x'_9
						x'					

Para melhor compreensão, abaixo segue a aplicação da Equação 2.4 para o cálculo do valores em destaques(*) na Tabela 2.1.

Para $i = 0$ e $j = 0$, temos $x_0 = 1$, $x'_0 = 1$, $x_{0-1} = null$ e $x'_{0-1} = null$, logo :

$$D_q(\mathbf{1}, \mathbf{1}) = |1 - 1| + \min(D_q(null, null), D_q(null, null), D_q(null, null))$$

$$D_q(\mathbf{1}, \mathbf{1}) = |0| + \min(null, null, null) = 0$$

Para $i = 7$ e $j = 3$, temos $x_7 = 6$, $x'_3 = 4$, $x_{7-1} = 2$ e $x'_{3-1} = 3$, logo :

$$D_q(\mathbf{6}, \mathbf{4}) = |6 - 4| + \min(D_q(2, 4), D_q(6, 3), D_q(2, 3))$$

$$D_q(\mathbf{6}, \mathbf{4}) = |2| + \min(12, 15, 11) = 2 + 11 = 13$$

Para $i = 9$ e $j = 9$, temos $x_9 = 4$, $x'_9 = 4$, $x_{9-1} = 8$ e $x'_{9-1} = 7$, logo :

$$D_q(\mathbf{4}, \mathbf{4}) = |4 - 4| + \min(D_q(8, 4), D_q(4, 7), D_q(8, 7))$$

$$D_q(\mathbf{4}, \mathbf{4}) = |0| + \min(18, 18, 15) = 0 + 15 = 15$$

Uma vez preenchida a matriz de custos $D_q(x, x')$ é possível identificar caminho do alinhamento A_π de menor valor caminhando pela tabela, fazendo o caminho reverso de sua construção. Para tal, basta identificar o menor valor entre as células adjacentes (x_i, x'_{j-1}) , (x_{i-1}, x'_j) e (x_{i-1}, x'_{j-1}) , iniciando da última célula calculada.

Tabela 2.2: Caminho do alinhamento de menor custo.

x_9	4	42	24	2	17	20	25	19	18	18	15	
x_8	8	39	21	19	17	20	19	18	15	15	18	
x_7	6	32	20	15	13	17	28	15	15	14	16	
x_6	2	27	19	11	12	12	20	14	13	17	18	
x	x_5	3	26	14	10	11	13	16	11	12	16	17
	x_4	9	24	10	14	16	19	9	12	17	18	21
	x_3	10	16	8	12	11	14	8	13	18	16	21
	x_2	5	7	5	5	5	8	12	12	13	15	16
	x_1	4	3	3	4	4	7	13	14	14	17	17
	x_0	1	0	6	8	11	11	20	24	27	33	36
			1	7	3	4	1	10	5	4	7	4
			x'_0	x'_1	x'_2	x'_3	x'_4	x'_5	x'_6	x'_7	x'_8	x'_9
							x'					

Então, para a série x e x' , foi possível obter a partir da matriz de custos $D_q(x_i, x'_j)$ o caminho do alinhamento de menor custo $A_\pi = \{0, 3, 4, 4, 8, 8, 9, 11, 13, 14, 15, 15\}$ de tamanho $K = 12$. Com base em A_π e K , temos que a distância entre x e x' é dada por: $D(x, x') = \text{sum}(A_\pi)/K = 104/12 = 8.63$, ou seja, quanto mais próximo de 0, mais similares são as séries x e x' . Esta seção foi desenvolvida através de adaptações das das informações providas por [Tavenard \(2021\)](#); [Vintsyuk \(1968\)](#); [Sakoe e Chiba \(1978\)](#); [Zhang \(2020\)](#)

2.4 Máquinas de Boltzmann

As Máquinas de Boltzmann, proposta por [Hinton \(2007\)](#), é uma rede neural estocástica simetricamente conectada, onde todos os elementos estão conectados uns aos outros (ver Figura 2.6). Estes elementos, similares aos neurônios, são chamados de nós e estão divididos em 2 tipos de camadas: a visível e a oculta. Diferente das redes neurais tradicionais, que possuem uma camada de entrada, uma ou várias camadas ocultas e uma camada de saída, as Máquinas de Boltzmann possuem um algoritmo de aprendizagem simples que as permitem descobrir características interessantes em bases de dados composta por vetores binários.




Figura 2.6: Representação gráfica de uma Máquina de Boltzmann com 4 nós visíveis ($v_1 \dots v_4$) e 3 nós ocultos ($h_1 \dots h_3$).

Segundo [Hinton \(2007\)](#), estas redes, à princípio, resolvem dois tipos de problemas:

(i) Busca: quando os pesos das conexões são fixos e são usados para representar a função de

custo em um problema de otimização, permitindo que a dinâmica estocástica gere vetores binários que representem boas soluções para o problema de otimização e; (ii) Aprendizagem: onde, dado um conjunto de vetores binários como entrada, os pesos são recalculados a cada iteração buscando encontrar a melhor combinação de valores para que os vetores de entradas sejam considerados boas soluções para o problema de otimização.

Estas redes neurais tem como objetivo aprender, a partir de um conjunto de entrada, os padrões implícitos e, posteriormente, ser capaz de suprir a ausência ou má qualidade dos dados para novas entradas através das iterações estocástica durante sua execução (Thiam 1999).

Assim como os neurônios das redes neurais artificiais, cada nó i atualiza seu estado binário (z_i) somando seu próprio valor de viés (b_i) ao somatório dos valores obtidos dos produtos entre os pesos de suas conexões aos valores dos nós ativos a ele conectado, conforme apresentado na Equação 2.5.

$$z_i = b_i + \sum_j s_j w_{ij} \quad (2.5)$$

Onde w_{ij} é o peso da conexão entre o nó i e j e, s_i é o valor binário do nó j , sendo 1, caso esteja ativo ou 0 caso contrário. A função de ativação do nó i é dada pela probabilidade calculada na Equação 2.6:

$$\text{prob}(s_i = 1) = \frac{1}{1 + e^{-z_i}} \quad (2.6)$$

A Equação 2.6 é executada em todos os nós da rede permitindo alcançar a distribuição de Boltzmann, ou distribuição estacionária na qual, a probabilidade de um vetor de estado v é determinada apenas pela *energia* desse vetor de estado em relação às energias de todos os vetores de estado binários possíveis. Esta probabilidade pode ser calculada por meio da Equação 2.7.

$$P(v) = e^{-E(v)} / \sum_u e^{-E(u)} \quad (2.7)$$

A energia do vetor de estado v é dada pela Equação 2.8 sendo s_i^v o estado binário

para o nó i no vetor v .

$$E(v) = - \sum_i s_i^v b_i - \sum_{i < j} s_i^v s_j^v w_{ij} \quad (2.8)$$

Como é possível perceber, estas redes possuem um custo computacional muito elevado devido a quantidade de cálculos que devem ser realizados para cada nó da rede. Este elevado custo dá-se por ser uma rede simétrica em que todos os nós estão conectados uns aos outros.

2.4.1 Máquina de Boltzmann Restrita

Um método para mitigar o custo computacional das Máquinas de Boltzmann é apresentado por [Smolensky \(1986\)](#). O mesmo impõe restrições sobre as conexões entre os nós da mesma camada (ver Figura 2.7).




Figura 2.7: Representação gráfica de uma Máquina de Boltzmann Restrita com 4 nós visíveis ($v_1 \dots v_4$) e 3 nós ocultos ($h_1 \dots h_3$).

Tais restrições possibilitam uma melhora significativa no desempenho desta rede uma vez que os nós da camada oculta são condicionalmente independentes de um vetor na camada visível. Dessa forma é possível obter uma melhoria substancial no processo de descoberta, tanto do estado estacionário, quanto do vetores binário de valores dos nós. Apesar de ainda exigir várias iterações para chegar ao estado estacionário para calcular os pesos e para identificar o vetor binário, é possível aplicar o paralelismo durante o processamento de dados, otimizando sua execução.

2.4.2 Processo de aprendizagem nas Máquinas de Boltzmann

Dado um conjunto de vetores de estados, o aprendizado consiste em identificar pesos (w) e viés (b) que façam os vetores serem boas soluções para o problema de otimização. Em outras palavras, busca-se achar os pesos e viés que representem a distribuição de Boltzmann, ou a distribuição estacionária, em que os vetores de treinamento tenham alta probabilidade de ocorrer. Este treinamento é representado pela Equação 2.9:

$$\sum_{v \in data} \frac{\partial \log P(v)}{\partial w_{ij}} = \langle s_i s_j \rangle_{data} - \langle s_i s_j \rangle_{model} \quad (2.9)$$

Sendo $\langle s_i s_j \rangle_{data}$ o valor esperado para $s_i s_j$ na distribuição de dados e $\langle s_i s_j \rangle_{model}$ o valor esperado das amostras do vetor de estados ao alcançar o equilíbrio na distribuição. Este processo iterativo permite que as amostras atualizem os valores dos pesos w_{ij} em pequenas taxas de aprendizagem, o mesmo ocorre para o valor do viés b .

2.5 Resumo

No Capítulo 2 foram descritos todos os conceitos, definições e teorias que dão suporte ao desenvolvimento da solução apresentada nesta Tese. Foram apresentados os fundamentos sobre os sensores inerciais, sua composição, quais valores são mensurados e as principais unidades em que os dados são providos. Também foram introduzidas informações sobre o *Dynamic Time Warping*, descrevendo sua diferença para a Distância Euclidiana, a formalização do problema e sua solução através da programação dinâmica. Por último, mas não menos importante, explanou-se sobre as Máquinas de Boltzmann e sua especificação, as Máquinas de Boltzmann Restritas, detalhando sua composição, seu funcionamento e como ocorre o processo de aprendizagem nestas redes neurais.

Capítulo 3

Trabalhos Correlatos

Esta seção está subdividida em dois tópicos: (i) bases de dados públicas baseadas em sensores inerciais; e (ii) uso de *machine learning* para monitoramento de atividades físicas. Em ambos tópicos executou-se uma busca ad-hoc de literatura que permitiu mapear os trabalhos mais similares ao método proposto por esta tese, bem como o mapeamento de base de dados públicas que pudessem ser utilizadas para avaliação do método proposto

3.1 Bases de dados públicas baseadas em sensores inerciais

Esta pesquisa identificou 32 bases de dados públicas através de pesquisas voltadas para o Reconhecimento de Atividade Humana baseada em sensores inerciais. Todas as bases tiveram suas contribuições significativas para o progresso da ciência e continuam servindo de objeto de estudos para outros pesquisadores. Nosso objetivo é mapear as similaridades e diferenças entre elas.

A avaliação das bases de dados identificados por esta pesquisa será dividida em 4 partes: Seção 3.1.1 onde serão descritos as características e os principais componentes e dispositivos usados para produção das bases de dados; Seção 3.1.2 destacando os principais pontos de monitoramento do corpo; Seção 3.1.3 onde as atividades monitoradas foram agrupadas em escopos que definem o contexto no qual foram realizadas e; Seção 3.1.4 na qual cada base

será avaliada individualmente, apresentando suas características positivas e negativas.

3.1.1 *Hardware*s

Esta seção lista os *hardwares* utilizados para produção dos conjuntos de dados encontrados por esta pesquisa. Atributos como conjuntos de sensores, frequências de amostragem, sensibilidade e tipos de dados proporcionam aos usuários uma visão ampla sobre as principais características das tecnologias aplicadas na formação das bases.

Os componentes e dispositivos estão divididos em duas tabelas: Tabela 3.1 baseada em dispositivos (*smartphones/smartwatch*) e; Tabela 3.2 baseada em componentes (módulos inerciais). Esta divisão deu-se principalmente por falta de documentação detalhada por parte dos fabricantes de dispositivos, impossibilitando a identificação dos componentes internos usados para realizar as leituras dos sensores. Dessa forma, a Tabela 3.1 apresenta apenas as informações sobre quais sensores estão presentes nos dispositivos, enquanto que a Tabela 3.2 apresenta com mais detalhes as características dos sensores utilizados.

Na Tabela 3.1 podemos destacar os dispositivos *Samsung Galaxy S+*, *Realme C3* e *Motorola MU860* os quais não possuem giroscópio. Além destes, o *smartwatch Samsung Galaxy Gear* não possui magnetômetro em seu *hardware*. Os demais dispositivos possuem os três sensores principais para coleta de dados inerciais, embora nem todos tenham sido usados para desenvolvimento das pesquisas.

Os trabalhos de Sikder e Nahid (2021) e Stisen *et al.* (2015) reportaram que realizaram as coletas de dados de acelerômetros e giroscópios, sendo que os dispositivos *Samsung Galaxy S+* e *Realme C3* não possuem giroscópio. Entretanto, os autores justificam seu uso pelo fato da coleta também fazer uso de outros dispositivos, isto é, *Galaxy J7*, *Redmi Note 4* *Realme 51*, *C3* e *3 Pro*, que estão aptos a coletar dados tanto do acelerômetro quanto do giroscópio.

Na pesquisa de Ngo *et al.* (2014), os autores não fizeram o uso do giroscópio para a coleta de dados. Situação similar ocorre para o uso do *Samsung Galaxy Gear* (Stisen *et al.* (2015)), em que a ausência do magnetômetro não interferiu na coleta de dados uma vez que ambos sensores não foram considerados durante a coleta.

A pesquisa apresentada por Papamichail *et al.* (2019) utilizou-se de um *Redmi Note*

Tabela 3.1: Sensores presentes nos dispositivos identificados.

Referência	Dispositivo	Ace.	Gir.	Mag.
Shoaib <i>et al.</i> (2014); Anguita <i>et al.</i> (2012)	Samsung Galaxy S2	x	x	x
Stisen <i>et al.</i> (2015)	Samsung Galaxy S3 Mini	x	x	x
Stisen <i>et al.</i> (2015); Vavoulas <i>et al.</i> (2016)	Samsung Galaxy S3	x	x	x
Stisen <i>et al.</i> (2015)	Samsung Galaxy S3	x	x	x
Stisen <i>et al.</i> (2015)	Samsung Galaxy S+	x		x
Sztyler (2019)	Samsung Galaxy S4	x	x	x
Permatasari <i>et al.</i> (2020)	Samsung Galaxy S5	x	x	x
Weiss <i>et al.</i> (2019)	Samsung Galaxy S6	x	x	x
Sikder e Nahid (2021)	Samsung Galaxy J7	x	x	x
Stisen <i>et al.</i> (2015)	Samsung Galaxy Gear	x	x	
Sikder e Nahid (2021)	Realme C3	x		x
Sikder e Nahid (2021)	Realme 3 Pro	x	x	x
Sikder e Nahid (2021)	Realme 5i	x	x	x
Permatasari <i>et al.</i> (2020)	LG G4	x	x	x
Stisen <i>et al.</i> (2015)	LG Nexus 4	x	x	x
Weiss <i>et al.</i> (2019)	LG Nexus 5	x	x	x
Weiss <i>et al.</i> (2019)	LG Nexus 5X	x	x	x
Stisen <i>et al.</i> (2015); Weiss <i>et al.</i> (2019)	LG G Watch	x	x	x
Sztyler (2019)	LG G Watch R	x	x	x
Sikder e Nahid (2021)	Redmi Note 4	x	x	x
Ngo <i>et al.</i> (2014)	Motorola ME860	x		x
Malekzadeh <i>et al.</i> (2018)	iPhone 6s	x	x	x

Acelerômetro; Giroscópio; Magnetômetro; (vazio):Não possui

e, nos estudos de Permatasari *et al.* (2020), os autores indicaram o uso de dispositivos *Android*. Em ambos os casos não há especificações sobre a versão dos *smartphones* utilizados, impossibilitando a identificação dos sensores disponíveis. O mesmo ocorreu para Kwolek e Kepski (2014), que fez uso do dispositivo *PSMove* (Sony 2016), controle de videogame que possui sensores inerciais, porém não foi possível identificar quais. Outra base que também carece de informações sobre os sensores está na pesquisa de Niemann *et al.* (2020), indicando o uso de hardware da *Texas Instrument* e da *MotionMiners* (Miners 2021), sendo este último um sistema de monitoramento de ambientes inteligentes. Nos estudos conduzidos por Badar ud din Tahir *et al.* (2020); Bächlin *et al.* (2010) e Forster *et al.* (2009) os autores não identificaram os dispositivos/componentes utilizados, informando apenas que os sensores fornecem

Tabela 3.2: Limites suportados pelos sensores em cada componente inercial encontrado.

Referências	Componente	Acelerômetro (g)	Giroscópio ($^{\circ}/s$)	Magnetômetro (μT)	Taxa de amostra (Hz)
Villa <i>et al.</i> (2022)	NGIMU	± 16	± 2000	± 1300	100
Zappi <i>et al.</i> (2012)	ADXL330	± 3.6			500
Reiss e Stricker (2012)	Colibri Trevisio	± 6	± 2000	± 130	100
Jalal <i>et al.</i> (2020)	GY-521	± 16	± 2000		1000
Ngo <i>et al.</i> (2014)	KXTF9 (Motorola ME860)	± 8			800
Chavarriaga <i>et al.</i> (2013)	Inertiacube3	-	± 1200	-	180
Saha <i>et al.</i> (2018)	LIS2DH	± 16			5300
Vavoulas <i>et al.</i> (2016)	LSM330DLC (Galaxy S3)	± 16	± 2000		800
Saleh <i>et al.</i> (2021)	LSM9DS1	± 16	± 2000	± 1600	400000
Niemann <i>et al.</i> (2020)	MbientLab	± 16	± 2000	(x,y): ± 1300 (z): ± 2500	800
la Torre <i>et al.</i> (2008)	3DM-GX1	± 18	± 1200	± 120	350
Zhang e Sawchuk (2012)	MotionNode	± 6	± 2000	± 100	10
Casilari <i>et al.</i> (2017)	MPU-6500 (Galaxy S5)	± 16	± 2000		8000
Jalal <i>et al.</i> (2019); Casilari <i>et al.</i> (2017); Bhat <i>et al.</i> (2020)	MPU-9250	± 16	± 2000	± 4800	8000
Banos <i>et al.</i> (2014); Ansari <i>et al.</i> (2017)	ShimmerIMU2	± 6	± 2000	± 450	512
Chavarriaga <i>et al.</i> (2013)	XSens	± 16	± 2000	-	2000
Kwolek e Kepski (2014)	x-IMU	± 8	± 2000	± 810	512

(vazio):Não se aplica; -:Não documentado;

dados sobre a aceleração do corpo monitorado, ou seja, acelerômetros.

Além dos sensores presentes em *smartphones/smartwatches*, a Tabela 3.2 detalha a sensibilidade dos sensores e taxa máxima de amostragem para os módulos e componentes inerciais identificados. Vale ressaltar que nem todos os estudos fizeram uso da capacidade

máxima dos componentes, ou seja, não utilizaram suas taxas máximas de amostragem, de sensibilidade e/ou não fizeram uso de todos os sensores existentes. Além disso, alguns fabricantes não especificaram em suas documentações os valores para alguns sensores.

Observando os atributos explicitados na Tabela 3.2, podemos destacar também o componente LSM9DS1 (STMicroelectronics 2015) que possui a taxa de amostragem mais elevada que os demais, podendo fazer leituras em até 400 kHz, ou seja, 400.000 leituras por segundo. Já o componentes 3DM-GX1 (Strain 2020) se destaca por suportar acelerações que variam de -18 g até +18 g. Para os giroscópios a exceção está nos componentes Inertiacube3 (Technologies 2021) e no 3DM-GX1 (Strain 2020) que suportam leituras de $-1200^\circ/s$ até $+1200^\circ/s$, valores inferiores aos $\pm 2000^\circ/s$ dos demais componentes. Entre os valores para o magnetômetro, aplicando a conversão de *Tesla* para *Gauss* ($1G = 100\mu T$), é possível destacar os componentes MPU-9250 (Inversense 2014), que suporta de -4800 à +4800 equivalentes à ± 4.8 gauss.

Para alguns componentes não foi possível obter mais detalhes sobre os sensores utilizados, como é o caso do *Inertiacube3* (Technologies 2021) que, inclusive no manual do fabricante, não há especificações sobre a sensibilidade do acelerômetro nem do giroscópio. O mesmo ocorre para a sensibilidade do magnetômetro do *XSens* (xSense 2021). Outros componentes não possuem os sensores de giroscópio (ADXL330 (Devices 2007), KXTF9 (Kionix 2019) e LIS2DH (STMicroelectronics 2011)) e nem magnetômetro (ADXL330 (Devices 2007), GY521 (Inversense 2012), KXTF9 (Kionix 2019), LIS2DH (STMicroelectronics 2011), LSM330DLC (STMicroelectronics 2012), MPU-6500 (Inversense 2013)).

O uso de tais componentes muitas vezes estão combinados com outras tecnologias que permitem tanto armazenar quanto transmitir os dados. Tais tecnologias podem variar de acordo com a época na qual as coletas foram realizadas.

3.1.2 Pontos de Monitoramento

Além do hardware utilizado para geração dos conjuntos de dados, outro atributo importante que merece destaque é o posicionamento dos sensores no corpo. Este atributo é útil para mapear os movimentos de um determinado membro do corpo e, caso não esteja bem posicionado, pode afetar diretamente a qualidade dos dados coletados e, conseqüentemente, prejudicar a

capacidade de classificação correta do movimento.

A Figura 3.1 mostra as 24 posições mais utilizadas entre as pesquisas para posicionamento dos sensores inerciais durante a coleta de dados e a Tabela 3.3 apresenta a distribuição de sensores por base de dados citada.

Neste caso, é importante notar que o ideal é que os sensores inerciais sejam posicionados em segmentos não articulados do corpo, tais como cabeça, tórax, braços, antebraços, cintura, coxas, pernas, pés, dorso. Tal restrição se dá porque tais segmentos se comportam como um objeto único que pode gerar valores significativos ao executar movimentos amplos. Diferentes destes, articulações ou pontos de flexões do corpo, como cervical, pulsos, mãos, joelhos, cotovelos e tornozelos não são capazes de prover informações relevantes sobre os movimentos executados pelos segmentos associados às articulações. Para estes, recomenda-se o uso de sensores de flexão ou resistivo. Vale ressaltar que o uso de sensores nos tornozelos e pulsos geralmente são uma opção mais prática para monitorar as extremidades dos membros superiores/inferiores e não necessariamente as articulações.

Nota-se também que alguns estudos fugiram ao posicionamento usual dos sensores. No trabalho de [Permatasari et al. \(2020\)](#) os sensores também foram posicionados em uma sacola de mão (de tamanho variado) e em uma mochila (sem compartimento definido). Tais escolhas foram baseadas em um levantamento realizado entre os participantes que indicaram os pontos mais frequentes que carregam seus *smartphones*. Outro estudo, apresentado por [Forster et al. \(2009\)](#), também define um posicionamento diferenciado, onde vários sensores foram distribuídos no mesmo membro, no caso, 10 na perna/coxa direita e 8 no braço/antebraço direito. Este, por sua vez, tinha como objetivo coletar dados mais precisos dos gestos realizados pela perna e braço.

Apesar das exceções, os pesquisadores tendem a usar 3 critérios para posicionamento dos sensores: (i) monitoramento de corpo único; (ii) monitoramento de membro articulado; e (iii) monitoramento de corpo complexo com múltiplas articulações.

No caso do *monitoramento de corpo único* considera-se aspectos mais amplos acerca do movimento e assume-se como premissa que o corpo se move como um todo quando executando a atividades ([Anguita et al. 2012](#); [Saha et al. 2018](#); [Malekzadeh et al. 2018](#); [Papamichail et al. 2019](#); [Sikder e Nahid 2021](#)). Exemplos de atividades podem ser: contagem de passos,




Figura 3.1: Principais posicionamentos dos sensores no corpo.

sentar, levantar, saltar, cair, dentre outros.

No *monitoramento de membro articulado* busca-se monitorar o comportamento de uma parte específica do corpo ou reconhecer movimentos específicos para um membro articulado, por exemplo, o reconhecimento de gestos, controle de casas inteligentes e monitoramento de pacientes com problemas neuromotores, como apresentados por [Abdel-Basset et al. \(2021\)](#); [Forster et al. \(2009\)](#); [Ngo et al. \(2014\)](#); [Chavarriaga et al. \(2013\)](#); [Zappi et al. \(2012\)](#).

Por último, no *monitoramento de corpo complexo com múltiplas articulações*, busca-se monitorar e analisar as correlações entre os múltiplos segmentos do corpo e como eles interagem entre si ao executar uma determinada atividade, por exemplo, o reconhecimento de atividades diárias e padrões em atividades físicas ([Jalal et al. 2019](#); [Badar ud din Tahir et al. 2020](#); [Jalal et al. 2020](#)).

De acordo com a Tabela 3.3, que mostra os principais posicionamentos dos sensores no corpo das bases de dados encontradas neste estudo, percebe-se que os pulsos são o ponto com maior incidência de monitoramento, seguidos da cintura e dos braços, coxas e pernas. Tais posicionamentos permitem a identificação de diversas atividades diárias pois são segmentos com maior amplitude de movimento, exceto a cintura que, por seu posicionamento, está vinculado ao centro de gravidade do corpo, sendo ideal para mapear eventos associados

Tabela 3.3: Relação de estudos por posição dos sensores.

Dataset	Cabeça	Cervical	Tórax	Dorso	Braços	Antebraços	Cintura/Lombar	Pulsos	Mãos	Bolsos	Coxas	Pernas	Tornozelos	Pés
PHYTMO					x	x					x	x		
IM-WSHA			x					x			x			
IM-SB			x					x			x			
MHealth			x					x					x	
Real Displacement				x	x	x					x	x		
HHAR								x		x				
HARD							x							
HugaDB											x	x		x
PAMAP2								x					x	
KU-HAR							x							
FallAID			x				x	x						
WISDM								x		x				
LARa			x				x	x					x	
USC-HAD							x							
RealWorld	x		x		x	x	x				x	x		
DU-MD								x						
SARD					x		x	x		x				
SMotion							x							
CMU-MMAC				x	x	x					x	x		
MotionSense										x				
UTD-MHAD								x			x			
IM-AccGyro		x			x							x		
w-HAR													x	
Brain Run									x					
MMUISD				x					x	x				
UMAFall			x				x	x		x			x	
Opportunity		x		x	x	x	x	x	x			x		x
SKODA					x	x					x	x		
BodyAttack					x							x		
Daphnet							x					x		
UR-Fall							x							
Mobiact										x				
OU-ISIR							x							
TOTAL	1	2	7	4	9	6	12	13	3	7	9	10	5	2

ao equilíbrio como quedas, saltos, levantar, deitar e sentar.

Atipicamente, o estudo de [Papamichail *et al.* \(2019\)](#) busca identificar o padrão de movimento que o usuário faz enquanto interage com o próprio dispositivo por meio de um aplicativo. Este estudo tira proveito dos sensores inerciais presentes no dispositivo para prover informações acerca do comportamento do usuário permitindo a identificação/autenticação do mesmo. Diferente das demais abordagens, esta não está fixada em um segmento do corpo, apesar de estar posicionada na parte interna das mãos e poder, eventualmente, variar entre os lados.

3.1.3 Escopos de Monitoramento

Nesta seção definimos os escopos onde as coletas de dados foram realizadas. Os escopos ajudam a compreender quais atividades foram monitoradas por cada estudo.

Apesar da construção da base de dados ser voltada para a avaliação de um certo aspecto da biomecânica humana, muitas delas registraram movimentos que podem se adequar a outros escopos, possibilitando sua avaliação por técnicas de reconhecimento alternativas.

De acordo com as bases encontradas por esta pesquisa, foram identificados 6 escopos principais:

- **Atividades Diárias:** Atividades rotineiras, em casa ou no trabalho, como arrumar a casa, passar roupa, cozinhar, comer, subir e descer escadas, dormir, se deitar, sentar, usar o computador ou o telefone e assistir televisão;
- **Análise de caminhada:** Dados produzidos pela ação de caminhar com variações de direção, sentido e intensidade;
- **Detecção de quedas:** Monitoramento de eventos (reais ou simulados) de quedas ou iminência de quedas;
- **Atividades Esportivas:** Execução de esporte específico como futebol, ciclismo, atletismo, boxe e basquete;
- **Atividades Físicas:** Diferente do anterior, este escopo engloba os movimentos realizados em ambiente controlado para produção da base de dados. Estão limitadas a poucas

repetições ou execuções rápidas, por exemplo, agachar, pular, curvar-se, ajoelhar e rotacionar os braços;

- **Reconhecimento de gestos:** Ações que geralmente se concentram em utilizar um membro específico do corpo para a captura de dados, por exemplo, bater palmas, acenar, executar movimentos geométricos com as mãos e equilibrar-se em uma perna.

Uma vez descritos os hardwares, os posicionamentos mais frequentes e os contextos mais usuais, na próxima seção será feita uma comparação direta entre as bases de dados, confrontando atributos mais específicos e discorrendo sobre as especificações de cada uma delas.

3.1.4 Revisão das bases de dados

A Tabela 3.4 lista as bases encontradas e confronta atributos sobre as características dos participantes, hardware utilizado e o escopo de atividades que cada base de dados abrange.

Das 33 bases de dados encontradas, 23 (69%) fizeram o monitoramento de atividades diárias, seja em ambiente residencial ou no trabalho. Outras 22 (66%) bases apresentam dados úteis para análise de caminhada. Os dados para a detecção de quedas e/ou iminência de quedas, considerando sua complexidade de replicação e coleta de dados em cenário real, foram identificadas em apenas 5 (15%) bases. Para o escopo de atividades esportivas, foi possível identificar 7 (21%) bases de dados sendo uma delas, IM-SB (Badar ud din Tahir *et al.* 2020), exclusiva para tal. No contexto das atividades físicas, que contemplam atividades que geralmente são executadas em ambiente controlado, foram mapeadas 15 (45%) bases de dados e, por último, os dados quanto ao reconhecimento de gestos podem ser encontrados em 12 (36%) bases.

Observou-se que os estudos de Banos *et al.* (2014); Baños *et al.* (2012); Stisen *et al.* (2015); Weiss *et al.* (2019); la Torre *et al.* (2008); Chavarriaga *et al.* (2013); Zappi *et al.* (2012) e Forster *et al.* (2009) não forneceram dados sobre idade, peso e altura dos participantes dos experimentos, enquanto as pesquisas de Villa *et al.* (2022); Anguita *et al.* (2012); Sikder e Nahid (2021); Shoaib *et al.* (2014); Ansari *et al.* (2017); Jalal *et al.* (2020); Papamichail *et al.* (2019); Permatasari *et al.* (2020); Bächlin *et al.* (2010); Kwolek e Kepski (2014) e Ngo *et al.*

Tabela 3.4: Atributos sobre voluntários, sensores e escopos de atividades.

Dataset	Participantes				Sensores				Escopo					
	Quantidade	Faixa Etária	Peso (Kg)	Altura (cm)	Acelerômetro	Giroscópio	Magnetômetro	Quantidade	AD	AC	DQ	AE	AF	RG
PHYTMO	30	20-70	51-93	154-186	x	x	x	3		x		x	x	
IM-WSHA	10	19-60	55-85	-	x	x	x	3	x	x			x	
IM-SB	20	20-30	60-100	-	x			4				x		
MHealth	10	-	-	-	x	x	x	3	x	x		x	x	x
Real Displacement	17	-	-	-	x	x	x	9		x			x	x
HHAR	9	-	-	-	x	x		3	x	x			x	
HARD	30	19-48	-	-	x	x		1	x	x				
HugaDB	18	18-35	65-118	168-192	x	x		6		x		x	x	
PAMAP2	9	24-31	65-95	168-194	x	x	x	2	x	x		x		
KU-HAR	90	18-34	42-100	-	x	x		1	x	x		x	x	
FallAID	15	21-53	48-85	158-187	x	x	x	3	x	x	x		x	x
WISDM	51	-	-	-	x	x		2	x	x			x	x
LARa	14	22-59	52-100	163-185	x			6	x				x	x
USC-HAD	14	21-49	43-80	160-185	x	x		1	x	x				
RealWorld	15	19-45	60-88	166-180	x	x	x	7	x	x			x	
DU-MD	33	19-23	40-101	147-185	x			1	x	x	x			
SARD	10	25-30	-	-	x	x	x	5	x	x		x		
SMotion	-	18-90	35-90	-	x	x	x	1		x	x			
CMU-MMAC	39	-	-	-	x	x		5	x					x
MotionSense	24	18-46	48-102	161-190	x	x		1	x	x				
UTD-MHAD	6	-	-	-	x	x	x	2						x
IM-AccGyro	10	15-30	30-100	-	x	x		3		x		x	x	x
w-HAR	22	20-45	-	150-180	x	x		1	x					
Brain Run	400	20-50	-	-	x	x	x	1						x
MMUISD	299	18-28	-	-	x	x		1		x				
UMAFall	17	18-68	52-97	155-195	x	x	x	5	x	x	x		x	
Opportunity	12	-	-	-	x	x	x	19	x					x
SKODA	1	-	-	-	x			20						x
BodyAttack	1	-	-	-	x			8*					x	x
Daphnet	10	59-75	-	-	x			3	x	x				
UR-Fall	5	25-65	-	-	x	x		1	x		x			
Mobiact	66	20-47	50-120	160-193	x	x		1	x				x	
OU-ISIR	744	2-78	-	-	x	x		4		x				

-: Não Documentado; (**vazio**): não se aplica; *: 8 no braço/antebraço e 10 na coxa/perna

AD: Atividades diárias; **AC**: Análise de caminhada; **DQ**: Detecção de quedas;

AE: Atividades Esportiva; **AF**: Atividades Física; **RG**: Reconhecimento de Gestos;

(2014) descreveram parcialmente o biotipo dos mesmos. Apesar de tais atributos não serem relevantes em alguns cenários, o custo de se obter tais informações é irrisório em relação ao custo de produção dos dados. Tais atributos contribuem para uma descrição mais precisa do cenário em que a base foi produzida possibilitando a outros pesquisadores verificarem se a base de dados é adequada para seus experimentos ou não.

Para melhor organização, esta seção será subdividida em três tópicos, definidos de acordo com o hardware utilizado na coleta de dados, sendo: (i) *hardware* indefinido; (ii) componentes inerciais e módulos específicos; e (iii) *smartphones/smartwatches*.

***Hardware* indefinido**

Na base IM-SB (Badar ud din Tahir *et al.* 2020) os dados coletados durante a prática de esportes foram segmentados por atividade e voluntários, permitindo identificar atributos do participante que executou os movimentos, bem como a descrição da posição dos eixos de cada sensor. Apesar disso, os autores não especificam qual o hardware utilizado para monitoramento e, assim como em Jalal *et al.* (2019), os autores não identificaram em quais lados foram posicionados os sensores do pulso e da coxa.

Na base UTD-MHAD (Chen *et al.* 2015) os hardwares foram posicionados no pulso e perna direita e coletavam dados do acelerômetro (± 8 g), giroscópio ($\pm 1000^\circ/s$) e magnetômetro (sensibilidade não definida) a uma frequência de 50Hz. Foram executadas 4 repetições de movimentos variados no escopo de atividades físicas e reconhecimento de gestos, e um período jogando basquete. Esta base possui uma documentação bem clara quanto aos campos da base de dados, porém carece de informações sobre os participantes e do hardware.

Com o posicionamento de sensores que foge ao padrão apresentado na Seção 3.1.2, a base *BodyAttack* (Forster *et al.* 2009) fez uso de 10 acelerômetros distribuídos na coxa e perna direita e 8 distribuídos ao longo do braço e antebraço direito. Os sensores do membro superior coletaram dados a uma frequência de 96Hz e os sensores do membro inferior a uma frequência de 64Hz. As atividades físicas e os gestos executados foram monitorados por 30 segundos e 10 repetições respectivamente. Apesar da quantidade de sensores gerarem um mapeamento preciso dos movimentos executados, os autores não forneceram informações sobre o tipo de sensor usado, nem sobre a sensibilidade dos mesmos.

A base *Daphnet* (Bächlin *et al.* 2010) monitorou 10 participantes por um intervalo de 10 à 15 minutos para coleta de dados durante a caminhada e durante a execução de atividades físicas. Assim como a *SKODA* (Zappi *et al.* 2012), os autores não especificaram o hardware utilizado nem a sensibilidade dos sensores. Outra observação relevante é que, apesar da ausência de informações sobre o biotipo dos participantes, há informações sobre as condições de saúde dos mesmos, indicando o tipo de enfermidade e o tempo que ela perdura.

Componentes e Módulos

Destacando-se por sua descrição detalhada do cenário em que os experimentos foram executados, a base de dados LARa (Niemann *et al.* 2020) coleta de dados simulando um ambiente de logística (armazém), onde os usuários executaram movimentos variados na manipulação de objetos. Avaliando a documentação dos experimentos, foi possível identificar que os dados coletados para seis participantes se diferem dos oito restantes em relação a taxa de amostragem, além disso, não há indicação quanto à sensibilidade do acelerômetro.

Coletando dados do acelerômetro ($\pm 6g$) e giroscópio ($\pm 500^\circ/s$) a uma taxa de 100Hz, a base USC-HAD (Zhang e Sawchuk 2012) possui vasta documentação a respeito do cenário em que o monitoramento foi realizado. Apesar da documentação não abordar os dados dos usuários, os registros possuem informações sobre peso, altura e idade dos participantes. Em sua documentação também é possível identificar o posicionamento exato dos sensores e a orientação dos eixos em relação ao segmento monitorado. Assim como em *HugaDB* (Chereshnev e Kertész-Farkas 2018), as atividades foram repetidas/monitoradas várias vezes pelos participantes.

O acelerômetro LIS2DH (STMicroelectronics 2011) foi utilizado para geração da base *DU-MD* (Saha *et al.* 2018), onde, posicionado no pulso dominante dos voluntários, coletou dados a uma frequência de 30Hz durante dez segundos. A documentação descreve bem os atributos dos participantes, porém não descreve a sensibilidade do sensor nem as unidades em que os dados estão armazenados. Há também divergências em relação ao número de voluntários, sendo a Tabela 3.4 preenchida com o número de *logs* associados aos voluntários (33) e não o que foi documentado (50).

A pesquisa conduzida em Ansari *et al.* (2017) para produção da base de dados *SMo-*

tion, fez uso dos três sensores descritos na Seção 2.1 para coletar dados dos movimentos executados por idosos que os expõem ao risco iminente de quedas. Não foi documentada informações sobre o número de participantes, apenas a faixa etária e faixa de peso. As amostras foram coletadas a uma taxa de 50Hz e os dados armazenados foram armazenados em forma bruta e em unidade convertida para o acelerômetro (m/s^2) e giroscópio ($^\circ/s$).

Para a geração da base de dados *CMU-MMAC* (la Torre *et al.* 2008), os autores fizeram o uso de um acelerômetro e giroscópio para coletar dados inerciais do corpo dos voluntários enquanto estavam preparando diversos tipos de alimentos. Ao total, foram utilizados 39 voluntários. Porém a documentação carece de mais detalhes sobre os mesmos, além de não indicar a sensibilidade dos sensores e quais as unidades utilizadas para armazenamento de dados.

Por meio do sensor GY-521 (Inversense 2012) a base *IM-AccGyro* (Jalal *et al.* 2020) coleta os dados de 10 voluntários executando atividades de caminhada, esportes, atividades físicas e reconhecimento de gestos. A documentação esclarece que os sensores estão posicionados no pescoço, braço e perna, porém sem indicar o lado e orientação para os dois últimos,

Em *W-HAR* (Bhat *et al.* 2020), o uso do sensor MPU-9250 (Inversense 2014) possibilitou a coleta de dados a uma frequência de 250Hz. Os experimentos foram executados por 22 voluntários com sensores posicionados no tornozelo direito. O escopo desta base contempla a análise de atividades do dia a dia, coletando dados por um intervalo de 10 à 30 segundos ou 40 passos. Não há informações quanto a sensibilidade dos sensores nem sobre o peso dos participantes.

Uma das bases mais referenciadas para reconhecimento de atividade humana, a *Opportunity* (Chavarriaga *et al.* 2013) descreve detalhadamente as taxas de amostra dos sensores usados, que variam de 10 a 64 Hz, dependendo da posição do sensor. Para os 12 participantes foram registrados dados entre 10 a 25 minutos, tempo necessário para executar o conjunto de atividades definidas pelos autores. Embora a documentação descreva bem as condições de coleta de dados, e os campos da base de dados simulem bem um ambiente real, os autores não apresentaram dados sobre o biotipo dos participantes, além de não apresentar indicadores sobre a sensibilidade dos sensores.

Por meio do acelerômetro ADXL330 (Devices 2007), a base *SKODA* (Zappi *et al.* 2012) possui 3 horas de registros por participante, os quais executaram gestos variados. Os dados coletados dos membros superiores a uma frequência de 100MHz, possibilitaram o registro de gestos complexos, realizados ao longo da inspeção das partes de um veículo na linha de montagem. Esta base, porém, carece de informações mais detalhadas sobre os participantes e sobre as configurações de sensibilidade dos sensores utilizados.

Com foco em coletar dados durante a execução de atividades diárias e variações na caminhada, a base *UR-Fall* (Kwolek e Kepski 2014), coletou dados por meio dos hardware *PSMove* (Sony 2016) e do x-IMU (x IO 2013). Os registros são compostos de leituras dos acelerômetros e giroscópios posicionados na cintura de cinco participantes que repetiram as ações por três vezes. Os dados estão armazenados em g e em $^{\circ}/s$, além de incluir uma métrica identificada por aceleração total, dada pela fórmula: $\sqrt{x^2 + y^2 + z^2}$, a mesma usada pela base SARD (Shoaib *et al.* 2014), porém, aplicada apenas para o acelerômetro.

A documentação que descreve a base *IM-WSHA* (Jalal *et al.* 2019) não há especificações sobre a taxa de amostra dos sensores, tampouco há indicadores sobre qual lado do pulso/coxa foram posicionados os hardwares de monitoramento. Apesar do uso do sensor MPU-9250 (Inversense 2014), os autores não informaram quanto à sensibilidade definida durante os experimentos, nem a unidade/formato de armazenamento de dados. As atividades executadas pelos participantes foram registradas durante o intervalo de um minuto (ou durante 20 repetições) Os dados coletado para a produção das base *MHealth* (Banos *et al.* 2014) foram gerados por acelerômetros (m/s^2), giroscópios ($^{\circ}/s$) e magnetômetros (unidade não definida). Sua documentação limita-se a apresentar apenas a quantidade de participantes e indicar que a coleta de dados para todos os sensores foi realizada à 50Hz.

Com a proposta de prover dados para avaliar o impacto do deslocamento dos sensores durante o reconhecimento de atividade humana, a base *Real Displacement* (Baños *et al.* 2012) introduz um atributo atípico às demais bases de dados, os quatérnions (que consistem em uma generalização dos números complexos para quatro dimensões e são compostos por uma parte escalar e uma parte vetorial), cujo valor é baseado nas leituras dos sensores inerciais. A base possui três conjuntos de dados diferentes: (i) com o posicionamento ideal dos sensores; (ii) com um deslocamento controlado dos sensores e; (iii) com um dos sensores sendo posicionados

pelo próprio usuário. Vale ressaltar que apenas três dos dezessete participantes fizeram o posicionamento dos sensores.

Para a base *HugaDB* (Chereshnev e Kertész-Farkas 2018), o uso de sensores MPU-9250 (Inversense 2014) possibilitou a descrição detalhada do cenário de testes. Com o intuito de analisar, principalmente, a caminhada humana, os autores definiram a sensibilidade do acelerômetro em $\pm 2g$, do giroscópio em $\pm 2000^\circ/s$ e uma taxa de amostra de 56.35 kHz, permitindo captar as mínimas variações nas leituras dos sensores durante a execução das atividades. Diferente das demais bases, a *HugaDB* (Chereshnev e Kertész-Farkas 2018) possui dados brutos armazenados em inteiro não sinalizado de 16 *bits* (*uint 16*) para o acelerômetro e giroscópio. Esta base também provê um pacote de *scripts* em *python* que permite a visualização dos dados disponíveis. Vale ressaltar que alguns experimentos foram repetidos, gerando vários registros para o mesmo usuário e atividade.

Os dados do acelerômetro, giroscópio e magnetômetro, gerados pelo sensor *Colibri Trevisio* (Trevisio 2021) para produzir a base de dados *PAMAP2* (Reiss e Stricker 2012), foram armazenados em m/s^2 , $^\circ/s$ e μT respectivamente. Os dados mapeiam o movimento do corpo durante a execução de atividades físicas variadas. Embora os autores especifiquem a diferença na sensibilidade dos acelerômetros utilizados nos pulsos ($\pm 16g$) e pés ($\pm 6g$), não há informações sobre a sensibilidade dos demais sensores. Os autores se preocuparam em registrar o biotipo dos voluntários, além da ordem dos sensores em que os dados estão armazenados. Em sua documentação, também há indicadores que mapeiam os erros de leituras durante a coleta de dados. Outra observação relevante é que nem todos os experimentos foram executados por todos os participantes, limitando-se a no máximo oito atividades (escolhidas pelos participantes) por voluntário.

A base de dados *FallAllD* (Saleh *et al.* 2021), contrariamente ao que seu nome possa induzir, não se limita ao monitoramento de quedas, mas busca registrar os eventos e atividades que precedem a queda. Com sensores calibrados em $\pm 8g$, $\pm 2000^\circ/s$ e $\pm 4G$, os usuários foram monitorados executando atividades diárias, caminhadas, atividades físicas, gestos específicos, além de simular situações reais de quedas. Um ponto de destaque desta base é a amostra de dados que realiza leituras em até 238 Hz para os três sensores usados.

Smartphone/Smartwatches

Os experimentos realizados para gerar da base HHAR (Stisen *et al.* 2015) foram executados em cenário real com auxílio de *smartwatches* e *smartphones*. Os autores buscaram monitorar as mesmas atividades posicionando o *smartphone* em ângulos diferentes. Tal procedimento possibilita a geração de modelos mais robustos de classificação capazes de reconhecer a ação executada independente do posicionamento do *smartphone*. Apesar disso, os autores não indicaram qual unidade é usada para armazenar os dados, além de não indicar se os dispositivos foram utilizados simultaneamente ou não.

Baseado em *smartphone Samsung Galaxy S2*, os estudos desenvolvidos para formação da base *HARD* (Anguita *et al.* 2012) mapeiam os movimentos executados para atividades do dia a dia e análise de caminhada. Sua base possui valores normalizados entre $[-1, 1]$ considerando as unidades - m/s^2 para o acelerômetro e em $^\circ/s$ para o giroscópio. Um ponto importante desta base é a segmentação dos dados para formação da base de treino e base de testes, a qual segue uma divisão amplamente usada para geração de modelos de aprendizagem de máquina (70% para treino e 30% para testes). Há também atributos incrementais à base que são processados em janelas de intervalos de tempos de 2.56s, permitindo obter valores como média, mediana, desvio padrão e entropia.

A base de dados *KU-HAR* (Sikder e Nahid 2021) se destaca das demais por apresentar detalhadamente informações sobre os participantes, incluindo informações sobre problemas cardiovasculares e outros fatores limitadores. Através do uso de um sensor inercial na cintura, foi possível coletar dados brutos do acelerômetro (m/s^2) e do giroscópio ($^\circ/s$). Apesar das informações sobre os voluntários, o estudo não apresenta dados sobre a taxa de amostragem e a sensibilidade dos sensores.

A carência de informações sobre os voluntários e sobre o posicionamento preciso dos sensores se contrastam com a organização dos dados apresentados na base de dados *WISDM* (Weiss *et al.* 2019). Com uma documentação bem detalhada sobre os campos que compõem os arquivos de log, esta base se destaca por sua variedade de voluntários (51), número de atividades executadas (18) e escopos considerados (4).

Por meio do monitoramento com *smartphones* e *smartwatches*, a base *Real World* (Szttyler 2019), não descreve com precisão o posicionamento dos sensores, nem a sensibilidade

dos mesmo. Apesar disto, a descrição dos voluntários é bem detalhada além de possuir uma variação no intervalo de tempo para execução de cada atividade, capturando assim os movimentos executados em cenário real. Os arquivos são disponibilizados em dados brutos em formato CSV e em *dump* para *SQLite*.

A base de dados *SARD* (Shoaib *et al.* 2014) coletou dados de acelerômetro, giroscópio e magnetômetro a uma frequência de 50Hz para execução de atividades diárias, caminhada e prática de esportes. O posicionamento dos sensores (embarcados em um *Galaxy S2*) foram precisamente descritos na documentação, inclusive a orientação dos eixos. Os autores também introduziram uma métrica identificada como magnitude, dada pela fórmula $\sqrt{x^2 + y^2 + z^2}$ e calculada para cada sensor individualmente. Não há indicações sobre o formato dos dados armazenados nem sobre a sensibilidade dos sensores.

Com uma base de dados segmentada por sensor, a *MotionSense* (Malekzadeh *et al.* 2018) fez uso de um iPhone 6s para coletar leituras do acelerômetro e do giroscópio. Todos os 24 voluntários posicionaram o sensor no bolso dianteiro, porém não há indicações sobre qual lado. As atividades (subir/descer escadas, sentar, levantar, caminhar, corrida leve) foram executadas em intervalos de tempos variados. A documentação não oferece uma descrição sobre o formato dos dados armazenados bem como não há informações sobre a frequência de amostra dos sensores.

Diferente das demais bases, a *Brain Run* (Papamichail *et al.* 2019), busca identificar o padrão de gestos dos usuários durante o uso do *smartphone*. Através de uma abordagem que envolve *gamificação* para coleta de dados, esta base possui dados de 400 participantes, de várias idades, porém não há mais especificações sobre os usuários.

A *MMUISD* (Permatasari *et al.* 2020) fez uso do acelerômetro e giroscópio presentes em *smartphones Android* (modelos não definidos) para coletar dados inerciais durante a caminhada. Os experimentos consistiram em realizar caminhadas em velocidades diferentes, permitindo a coleta de dados à 50 Hz por aproximadamente 2 minutos para cada iteração. A base conta registros de 299 participantes com uma faixa etária de 18 a 28 anos. Assim como vários outros experimentos, a documentação carece de informações sobre a sensibilidade dos sensores, unidade de armazenamento dos dados e informações sobre o biotipo dos participantes.

Com registros de atividades no escopo de atividades diárias, análise de caminhada, detecção de quedas e atividades físicas, a base *UMAFall* (Casilari *et al.* 2017) fez uso dos sensores existentes nos componentes MPU-6050 (Inversense 2013) e MPU-9250 (Inversense 2014) para coleta e armazenamento de dados em g (acelerômetro), $^{\circ}/s$ (giroscópio) e μT (magnetômetro). Vale ressaltar que o sensor MPU-6050 faz parte do *smartphone Galaxy S5*. Em sua documentação, os autores descreveram de forma precisa o posicionamento dos sensores, facilitando a reprodução dos experimentos.

Produzida por meio do sensor LSM330DLC (STMicroelectronics 2012) embarcado em um *Galaxy S3*, a base *MobiAct* (Vavoulas *et al.* 2016) coleta dados durante a execução de atividades diárias e exercícios físicos, considerando um acelerômetro e um giroscópio posicionado no bolso da calça (à escolha do participante). As atividades foram monitoradas em intervalos de 6 segundos a 5 minutos com um total de 66 participantes.

Por último, mas não menos importante, a base *OU-ISIR* (Ngo *et al.* 2014), monitorou 744 participantes através de sensores posicionados na cintura, coletando dados dos acelerômetros e giroscópios a 100Hz, durante a execução de caminhadas com variações de intensidade e orientação.

3.2 Monitoramento de Atividades Físicas

No contexto de monitoramento de atividades físicas, a abordagem convencional se concentra na identificação da atividade com base nos dados gerados por sensores acoplados ao corpo do usuário (Montull *et al.* 2022; Fuller *et al.* 2022; Lima *et al.* 2021) ou na avaliação de imagens de câmeras que registram os usuários durante os exercícios físicos (Verma *et al.* 2021). Eventualmente, uma técnica híbrida combina ambas (ou mais) fontes de monitoramento para gerar melhores modelos de classificação (Semwal *et al.* 2021; Bijalwan *et al.* 2022; Dua *et al.* 2023; Maskeliūnas *et al.* 2023). Embora esses métodos destaquem-se como o estado da arte no reconhecimento de atividades humanas, ainda são limitados a um modelo estático e previamente treinado, tornando-os incapazes de se adaptar e fornecer *feedbacks* relevantes aos usuários.

Este levantamento objetivou identificar abordagens focadas na geração de *feedbacks*

para correção de movimentos executados inapropriadamente. Dada a limitação de estudos com este mesmo propósito, foram considerados também pesquisas que identificavam execuções incorretas, sem a geração de *feedbacks* de ajustes.

Estudos como os apresentados por [Liao et al. \(2020\)](#); [Villa et al. \(2021\)](#); [Chen et al. \(2022a\)](#) propõem modelos capazes de reconhecer quando um movimento está sendo executado corretamente ou não. No entanto, quando estes modelos são incorporados em dispositivos vestíveis, falta-lhes a capacidade de se ajustarem ou adaptarem dinamicamente para reconhecer atividades que não foram incluídas na sua formação inicial. Além disso, os processos de generalização de aprendizagem profunda podem não ser adequados para todas as características físicas dos usuários e podem gerar *feedbacks* errôneos, o que pode levar a lesões ou lesões musculares. No contexto de exercícios físicos repetitivos, comumente realizados em academias ou em sessões de fisioterapia, os usuários tendem a alterar a própria capacidade muscular, podendo realizar os exercícios com mais destreza após múltiplas sessões, tornando o próprio modelo desatualizado ao longo do tempo.

O estudo mais semelhante encontrado na literatura propõe o uso de uma Máquina Boltzmann Restrita Recorrente para realizar previsões de séries temporais caóticas ([Li, Han e Wang 2020](#)). Apesar da divergência de aplicação, o método proposto seria um candidato interessante para solucionar o problema de pesquisa desta tese. Sua proposta inclui uma estrutura recorrente nos nós ocultos que armazena informações históricas, gerando previsões mais precisas para valores futuros para as séries temporais de entrada. Embora inovadora, não é possível definir a eficiência desta técnica para realizar ajustes nas séries temporais, sendo esta uma das recomendações de trabalhos futuros

Abordagens como as apresentadas por [Maskeliūnas et al. \(2023\)](#) fazem uso de câmeras e sensores de profundidade para avaliar a postura durante exercícios de reabilitação. Para tal, fez-se o uso de uma Máquina de Pose Convolutiva, que é uma técnica baseada na *Stacked Hourglass Network*, que busca criar várias camadas ocultas de convolução concatenadas sequencialmente. Este método consistiu em analisar 7 movimentos diferentes contendo 1 série correta e 2 séries de execuções erradas e foi capaz de obter melhores resultados que as Redes de Convolução tradicionais. Deve-se destacar ainda que esta técnica, assim como o método proposto nesta tese, busca avaliar os segmentos corporais de forma individual,

reduzindo ruídos gerados por outros segmentos. Apesar de seus avanços, este método está limitado ao número de atividades previamente treinadas.

Expandido a barreira do estado da arte, [Dua et al. \(2023\)](#) faz uso múltiplos sensores e técnicas de fusão de dados para realizar o reconhecimento de atividades físicas humanas. O método proposto consiste em usar uma *Convolutional Neural Network* para realizar o tratamento das imagens combinadas a uma *Gated Recurrent Unit* que é uma estrutura utilizadas para preservar características importantes dos dados de treinamento, ou seja, similar a uma memória de características relevantes que otimizam o modelo. A fusão ocorre nos dados dos sensores inerciais anexados aos segmentos corporais dos sujeitos durante a execução de atividades físicas. Os dados produzidos pelos sensores são sincronizados às imagens e são rotulados para que possam ser rotulados igualmente. Esta abordagem também faz uso de duas bases de dados, *MHEALTH* ([Banos et al. 2014](#)) e PMAP2 ([Reiss e Stricker 2012](#)), ambas identificadas na Tabela 3.4. Esta abordagem foi capaz de produzir um modelo com escopo significativamente amplo, sendo capaz de reconhecer satisfatoriamente atividades diárias, atividades esportivas, atividades físicas e análise de caminhada. Apesar de sua abordagem disruptiva, e resultados relevantes, esta abordagem ainda limita-se ao escopo de treinamento, não sendo capaz de reconhecer novos movimentos que não foram treinados. Além disso, dado sua complexidade, é necessário que um dispositivo disponha de recursos suficientes para suportar tal modelo.

O método proposto em [Conforti et al. \(2020\)](#) usa um classificador *Support Vector Machine* (SVM) para reconhecer padrões posturais por meio de sensores vestíveis para evitar posturas que aumentam o estresse da coluna vertebral. Esta abordagem treinou um modelo para reconhecer movimentos de levantamento e liberação com posturas corretas e incorretas usando dados cinemáticos de oito sensores distribuídos nas pernas e no tronco. Os experimentos envolveram 26 sujeitos saudáveis, e o modelo SVM alcançou uma precisão de 99,4% na identificação, em tempo real, de posturas corretas e incorretas, considerando todos os sensores. Apesar dos bons resultados, este modelo só funciona para esses movimentos (levantar e soltar cargas). Além disso, o SVM só gera resultados que já foram avaliados durante o processo de treinamento, ao contrário do RBM que pode se adaptar e gerar resultados com base em uma distribuição prévia do conjunto de dados de treinamento.

Os estudos realizados em [Liao et al. \(2020\)](#) fornecem uma estrutura de aprendizagem profunda capaz de avaliar até 10 exercícios de reabilitação. Ele usa um *autoencoder* como sub-redes para processar o deslocamento de partes individuais do corpo, que são monitoradas por um sensor visual de movimento. Suas conclusões demonstram que os modelos probabilísticos superam as abordagens que utilizam funções de distância para avaliações de movimento. Um segundo resultado desta pesquisa é um conjunto de dados denominado UI-PRMD com dados coletados de 10 indivíduos saudáveis, composto por 10 repetições de 10 exercícios de reabilitação. Esses dados foram coletados por um sistema de rastreamento óptico e consistem em seqüências de 117 dimensões de deslocamentos articulares angulares.

Uma abordagem diferente de reconstrução de séries temporais, proposta em [Huamin et al. \(2020\)](#), usa um *autoencoder* de eliminação de ruído (*denoising autoencoder* - DAE) para reconstruir séries temporais com valores ausentes. Ao converter a série temporal bruta em uma matriz 2D que estabelece correlações entre os intervalos de tempo, é possível usar um DAE para reconstruir o valor ausente na matriz 2D. Os resultados mostram que o uso de representações 2D de uma série temporal melhora o desempenho de imputação e classificação.

O estudo em [Villa et al. \(2021\)](#) avalia quatro técnicas de aprendizado de máquina em relação à classificação binária de um exercício. Atingiu um erro de classificação errada de até 0,5%, utilizando uma máquina de vetores de suporte com núcleo polinomial, e até 99% de precisão na detecção de movimentos errados considerando 7 exercícios diferentes em rotinas de fisioterapia. Conforme explicado anteriormente, esta abordagem também possui um número limitado de exercícios que é capaz de reconhecer e classificar, reduzindo suas aplicações devido às dificuldades de adição e remoção de diferentes rotinas. Além disso, os autores afirmam que o dispositivo vestível não consegue detectar uma variedade de movimentos de condicionamento físico e pode atrapalhar os exercícios dos usuários de condicionamento físico.

Uma abordagem interessante in [Chen et al. \(2022b\)](#) propõe o uso de transferência de aprendizagem baseada em redes neurais profundas para aumentar o número de aulas (atividades físicas) que poderiam ser avaliadas pelo modelo. Os experimentos de desempenho alcançaram até 98,56% de acurácia e 97,9% de precisão na identificação dos movimentos. Na completude do movimento atingiu até 92,84% de acurácia e 92,85% de precisão. Apesar dos bons resultados, a transferência tem um custo anterior de geração de um modelo genérico.

Além disso, a escalabilidade e as atualizações necessárias do modelo seriam difíceis de manter ao longo do tempo.

A Tabela 3.5 compara as principais características dos trabalhos correlatos ao método proposto nesta tese.

O método proposto nesta tese se destaca das abordagens apresentadas nesta seção

Tabela 3.5: Trabalhos Relacionados

Referência	Origem dos Dados	Método Aplicado	Escopo de Uso	Feedbacks
Li, Han e Wang (2020)	Temperatura, Umidade, Pressão	Máquinas de Boltzmann Restrita Recorrente	Variáveis ambientais	Predição de valores baseado em histórico.
Maskeliūnas et al. (2023)	Câmera e Sensores de Profundidade	Máquina de Pose Convolutiva	Exercícios de fisioterapia	Indicação de posicionamento errado do segmento corporal.
Dua et al. (2023)	Câmeras e Sensores Inerciais	Rede de Convolução e Unidade Recorrente Chaveada	Atividades Diárias, Físicas, Esportivas e Análise de Caminhada	Reconhecimento da atividade.
Conforti et al. (2020)	Sensores Inerciais	Máquina de Suporte Vetorial	Atividades Laborais que estressam a coluna	Indicação quando um movimento está inadequado.
Liao et al. (2020)	Câmera	Aprendizado Profundo e <i>Autoencoder</i>	Exercícios de reabilitação	Indicação por segmento se movimento está correto ou não.
Esta Tese	Sensores Inerciais	Máquina de Boltzmann Restrita	Atividade físicas repetitivas	Recomendação de ajustes no movimento executado

por oferecer aos usuários orientações de ajustes para que o movimento possa ser executado apropriadamente. Diferente dos modelos propostos, que consistem no pré-treinamento de movimentos que serão posteriormente reconhecidos, esta abordagem visa realizar treinamento curtos e específicos sempre que uma nova sessão de atividade física for iniciada. Tal característica permite que o método proposto se adapte a qualquer atividade física, produzindo modelos em tempo de execução, enquanto os demais estão limitados aos movimentos previamente treinados.

Um segundo ponto divergente do método proposto para os trabalhos relacionados está na capacidade de indicar os ajustes necessários para corrigir os movimentos. Com exceção do estudo de [Li, Hu, Zhu e Zhou \(2020\)](#), que realiza previsões de séries temporais produzindo os valores esperados ao longo da série, as demais abordagens limitam-se em avaliar o movimento e indicar a classe ao qual pertence. Este feedback, demasiadamente simplório, acaba restringindo os métodos propostos a um mecanismo de monitoramento do usuário.

Por último, mas não menos importante, problemas com o posicionamento dos sensores são contornados com o uso da métrica magnitude. Todos os métodos apresentados enfatizam a importância do posicionamento e orientação adequadas dos sensores ao longo do corpo para que os modelos sejam capazes de reconhecer os movimentos treinados. Estas abordagens buscam, através do mapeamento de pequenas variações no posicionamento dos sensores, generalizar os padrões dos movimentos reduzindo o impacto do posicionamento errado. No método proposto por essa tese, tanto o retreinamento de modelos quanto o uso da métrica magnitude corroboram para que esses problemas sejam mitigados.

Durante esta revisão de literatura, dentro de nossas condições, não foi possível encontrar um estudo capaz de satisfazer a questão principal que motiva nosso estudo: *como podemos propor uma abordagem para gerar modelos específicos, em tempo de execução, para auxiliar cada usuário com base em suas características físicas a realizar uma atividade física corretamente?*

3.3 Resumo

Neste capítulo é feito o levantamento de conjuntos de dados públicos candidatos para serem usados durante os experimentos de validação desta proposta de tese, além de fornecer um conhecimento sólido sobre posicionamento de sensores e tecnologias utilizadas. Também foi possível identificar métricas diferenciadas, propostas em alguns estudos, que são baseadas nas leituras dos sensores inerciais. Finalmente, foi feita uma comparação das principais características das abordagens identificadas na revisão de literatura e o método proposto nesta tese. Em um segundo momento, foi realizado um levantamento dos principais estudos na área de reconhecimento de atividade humana destacando métodos e tecnologias que potencialmente poderiam contornar os problemas apresentados nesta pesquisa.

Capítulo 4

Método Proposto

Esta tese propõe uma alternativa para alcançar os objetivos apresentados no Capítulo 1, defendendo que é possível, em tempo de execução, gerar um modelo capaz de orientar os usuários durante a prática de uma atividade física repetitiva a partir do uso de sensores inerciais que monitoram os movimentos realizados pelo segmento do corpo que está sendo ativado durante o exercício. Essa abordagem se distancia do processo de generalizações através da análise de várias amostras diferentes ao gerar um novo modelo no início de cada atividade distinta, identificando o padrão de movimento mais adequado para as características físicas do usuário naquele momento, respeitando suas limitações de acordo com seu progresso, evitando a sobrecarga dos músculos e mantendo a qualidade do movimento ao longo das séries de repetições da atividade física.

Este capítulo está subdividido em nas seguintes seções: (i) visão geral da arquitetura; (ii) seleção automatizada de amostras; (iii) binarização de séries temporais; e (iv) identificação das recomendações.

4.1 Visão geral

A Figura 4.1 ilustra o fluxo de para treinamento do modelo de RBM que fornecerá as recomendações de ajustes nos movimentos executados. Para tal, faz-se necessário inicialmente coletar os dados brutos dos sensores inerciais e convertê-los para a métrica magnitude. Nesta etapa é essencial a presença de um profissional qualificado para garantir a execução correta

dos movimentos. Esta exigência garante que os dados que serão usados para treinar o modelo refletem a execução apropriada da atividade física, permitindo que o modelo registre os parâmetros corretos para posteriormente corrigir execuções errôneas. Em um segundo momento é necessário fazer a seleção das amostras que é executada conforme apresentado na Seção 4.2. Posteriormente é realizada a binarização de cada amostra identificada, convertendo-se os dados de magnitudes para valores binários possibilitando suas inserções na camada visível da Máquina de Boltzmann Restrita. O modelo é treinado através da análise de todas as amostras binarizadas, ajustando-se os pesos que conectam os nós da camada visível e da camada oculta. Finalmente o modelo produzido, com os pesos atualizados, pode ser aplicado para análise de novas entradas.




Figura 4.1: *Pipeline* de treinamento do modelo.

Para cada atividade física, deve ser gerado um modelo específico, que retrate as condições físicas do usuário, e cada segmento onde está o sensor inercial. Além disso, caso as condições físicas do usuário modifiquem, um novo modelo deve ser gerado, de modo que este se adapte ao novo ritmo do usuário ao longo de sua evolução nas práticas de atividades físicas, evitando generalizações a partir de grandes conjuntos de dados. Adicionalmente, a avaliação de segmentos independentes mitiga problemas com a geração de ruídos por sensores adjacentes ao segmento monitorado durante as extrações e análises dos padrões.

Uma vez gerado o modelo, é possível avaliar novas séries temporais com valores de magnitude que representem execuções da mesma atividade física repetitiva, obtendo as amostras dos dados de entrada por meio de uma janela deslizante, convertendo-as em um vetor binário e então alimentando o modelo, que, baseado em uma distribuição prévia do conjunto de dados de treinamento, irá reconstruir/modificar os dados de entrada para satisfazer os padrões da execução correta do movimento, conforme ilustrado na Figura 4.2.

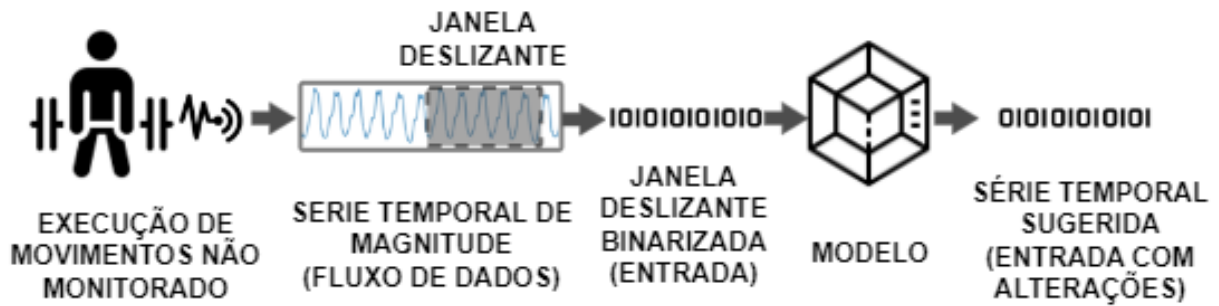


Figura 4.2: *Pipeline* de aplicação do modelo treinado para análise de novas entradas.


Este janela deslizante possui o comprimento igual à média das amostras obtidas durante o processo de treinamento, ou seja, o comprimento estimado de uma única execução do movimento repetitivo. Também leva-se em consideração que novas entradas apresentam seu valor de pico na posição média da janela deslizante, de forma similar ao que identificado na coleta de amostras durante o treinamento.

As modificações feitas pelo modelo RBM na amostra binária de entrada indicam os pontos onde a execução avaliada *deve* ser alterada para satisfazer o padrão de execução correto. Estas alterações vão indicar o valor esperado pelo modelo naquele determinado ponto, possibilitando a geração do *feedback* ao comparar a tendência ativada na entrada em relação à tendência ativada na saída.


É importante ressaltar que o processo de treinamento exige um conjunto de dados de alta qualidade para gerar um modelo RBM eficiente. A primeira série de cada atividade física deve ser executada sob supervisão de profissional habilitado que garanta a correta execução do movimento. Este requisito é essencial para fornecer dados confiáveis que possam servir de referência para a correção das execuções seguintes.

4.2 Seleção automatizada de amostras

Conforme apresentado na Seção 2.1, esta tese faz uso da métrica Magnitude, a qual combina os valores individuais dos sensores inerciais em um valor absoluto representando as forças de aceleração e rotação exercidas sobre os eixos x , y e z do IMU durante o movimento executado pelo segmento monitorado do corpo. Por se tratar de um valor absoluto não há valores negativos, o que permite associar diretamente valores crescentes ao aumento na força



(a) Primeira iteração com 24 centroides de 20 esperados.



(b) Última iteração em que foram encontrados 20 centroides de 20 esperados.

Figura 4.3: Iterações de decremento do limiar para identificação dos centroides em cada amostra ao longo da série temporal.

exercida sobre o sensor e valores decrescentes a uma diminuição da mesma. Com base nesse comportamento, esta tese propõe um método para realizar seleção automatizada de amostras que definem cada repetição do movimento físico avaliado.

Avaliando uma série (x) de uma atividade física repetitiva e tendo como entrada o número de repetições (n) realizadas durante a série, é possível estimar os sub-segmentos (amostras) de x que definem cada repetição do movimento realizado em apenas três etapas: (i) Identificar o conjunto de índices dos *centroides* (ponto central de cada amostra) da série (C) de tal forma que venham a se aproximar do número de repetições previamente conhecidos; (ii) Calcular a distância média entre os centroides ($AVG_{C_{dif}}$) permitindo a identificação do comprimento de cada amostra (tamanho do sub-segmento de x); e (iii) Calcular o intervalo de dados que compõe cada amostra sendo o início de cada uma em $C_i - (AVG_{C_{dif}}/2)$ e termina em $C_i + (AVG_{C_{dif}}/2)$, onde C_i é o índice do i -ésimo centóide em x e $AVG_{C_{dif}}$ a média da diferenças entre os índices de C .

A busca por centroides dá-se através de estimativas onde, em iterações decrementais, cada elemento de x é marcado com 0 caso seja inferior ao limiar ou 1 caso seja maior ou igual. O limiar inicia-se com o valor da média geral da série temporal (ver linha laranja na Figura 4.3a) e reduz gradativamente, até o menor valor da série temporal x ou até que o número de

grupos 1's seja igual ao número de repetições (n) previamente conhecido para esta série (ver linha laranja na Figura 4.3b). Uma vez identificados os grupos, são calculados os *centroides* (ver pontos verdes na Figura 4.3), que são marcações que indicam o meio de cada grupo de 1's, ou seja, o meio de cada amostra na série x , possibilitando identificar o início e o fim da amostra na série x baseado na distância média entre os centroides.

A redução do valor de limiar possibilita o agrupamento de valores que compõem uma mesma amostra ao longo da série x . Este comportamento pode ser observado ao compararmos o número de centroides e seus posicionamentos na Figura 4.3a em relação à Figura 4.3b. O resultado desta etapa pode ser observado na Figura 4.4 a qual apresenta as amostras coletadas durante a seleção automatizada na série temporal em Figura 4.3.

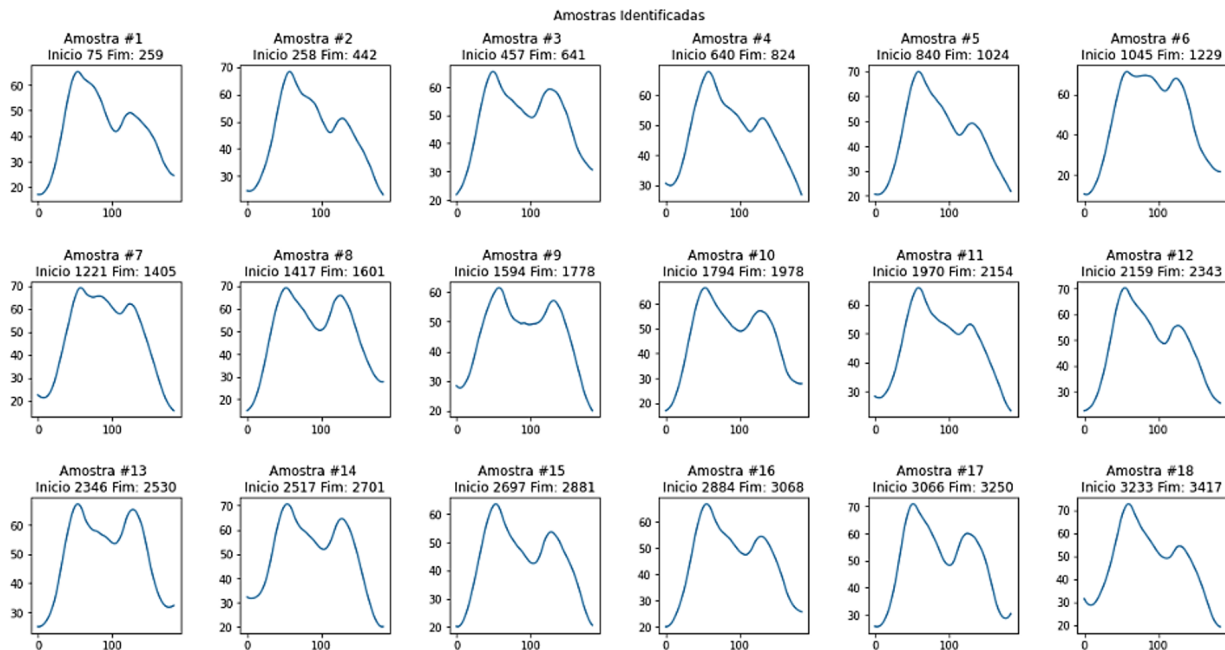


Figura 4.4: Amostras obtidas após o processo de seleção automatizada.

É notável um padrão consistente entre as amostras onde foi possível segmentar a série x em dezoito sub-segmentos similares que indicam um movimento repetitivo realizado de forma consecutiva. Ressalta-se também que ao longo das iterações é feito o ajuste do comprimento da amostra padronizando as repetições com o mesmo tamanho, neste caso há três ocorrências que devem ser observadas: (i) a sobreposição de dados na amostra (ver Figura 4.4 Amostras #8 e #9) que indicam uma execução de movimento ligeiramente diferente das de-

mais execuções; e (ii) Amostras incompletas nas extremidades da série temporal que acabam sendo descartadas por terem o comprimento menor que a distância média dos centroides.

4.3 Binarização de Séries Temporais

Uma vez obtidas as amostras, é necessário convertê-las para valores binários por meio de um processo de discretização para que sejam analisadas pela Máquina de Boltzmann Restrita (RBM). Este processo de discretização busca representar, através de uma tupla binária de três elementos (*tripla*), o comportamento ou tendência dos valores da amostra por meio da diferença entre os valores de magnitude nos instantes t e $t + 1$, indicando se neste intervalo a tendência é crescente (0,0,1), constante (0,1,0) ou decrescente (1,0,0). Isso significa que uma amostra s de tamanho m possui $3 \times (m - 1)$ elementos, ou $m - 1$ triplas.

Por exemplo, sendo $y = [0.45, 0.53, 0.69, 0.72, 0.7, 0.7, 0.68, 0, 65\dots]$ uma amostra extraída da série, a binarização considera a variação entre os valores y_t e $y_t + 1$ para gerar a tripla. neste caso, para o primeiro ($y_0 = 0.45$) e o segundo ($y_1 = 0.53$) elementos de y , temos $y_1 - y_0 = 0.53 - 0.45 = 0.08$. Sendo o resultado positivo ($0.08 > 0$), constatamos que entre y_0 e y_1 a magnitude aumenta, logo, sua tripla é composta da seguinte forma: (0,0,1). Seguindo este procedimento para os demais valores da série y , o vetor resultante de triplas será $y_{triplas} = [(0, 0, 1), (0, 0, 1), (0, 0, 1), (1, 0, 0), (0, 1, 0), (1, 0, 0), (1, 0, 0)\dots]$. Apesar de cada elemento de y corresponder a uma tripla, para a RBM todas as tuplas são combinadas sequencialmente, formando um vetor de valores binários conforme apresentado a seguir: $y_{bin} = [0, 0, 1, 0, 0, 1, 0, 0, 1, 1, 0, 0, 0, 1, 0, 1, 0, 0, 1, 0, 0\dots]$. Este vetor binário traduz as tendências de valores de magnitude na amostra o qual atuará como valor de entrada na camada visível da RBM. Este processo se repete no treinamento, nos testes e na avaliação dos modelos.

Uma vez identificadas as amostras e binarizadas, as mesmas são utilizadas para o processo de treinamento do modelo usando uma Máquina de Boltzmann Restrita que buscam fazer os ajustes nos pesos que conectam as unidades entre as camadas bem como os estados das unidades na camada oculta, conforme apresentado na Seção 2.4. O processo de binarização também se repete ao submeter uma nova série temporal para avaliação do

modelo e geração das recomendações, como será explicado na Seção 4.4.

4.4 Geração das recomendações

Para melhor compreensão deste processo, a Figura 4.5 ilustra o passo-a-passo das ações executadas pelo método proposto para gerar recomendações de ajustes para a seguinte série temporal de exemplo: $x = [0.7, 0.8, 1.2, 1.2, 0.95, 0.78, \dots]$. A ilustração também contempla o processo de reconstrução da nova série temporal que é gerada (i) a partir das tendências esperadas (séries binarizadas) do modelo RBM e; (ii) da diferença entre os valores adjacentes da série de entrada.

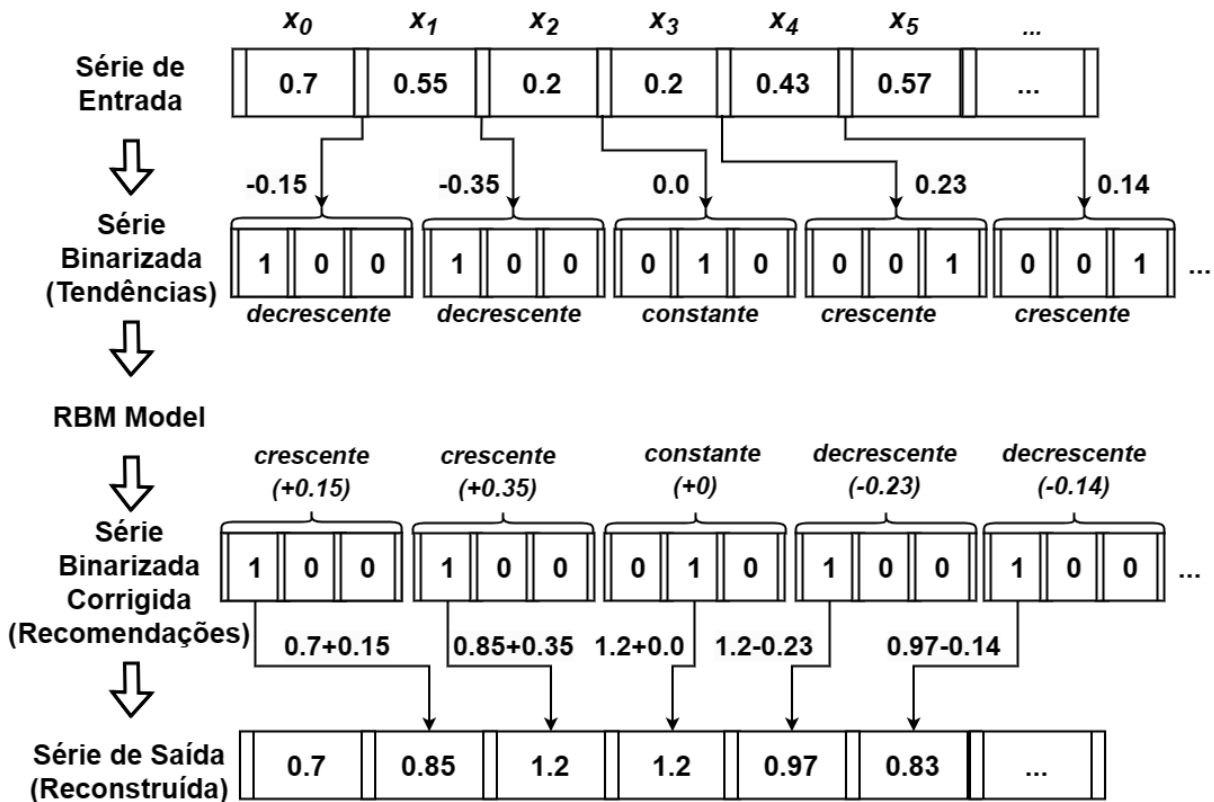


Figura 4.5: Etapas para binarização, geração das recomendações e reconstrução da série temporal.

Assim como no treinamento do modelo, as novas séries temporais de entradas também passam pelo processo de binarização para que possam ser dispostas nas unidades visíveis da Máquina de Boltzmann Restrita. Uma vez que é executado o processo de binari-

zação em x (Série de Entrada), é gerado o vetor $x_{bin} = [1, 0, 0, 1, 0, 0, 0, 1, 0, 0, 0, 1, 0, 0, 1, \dots]$ (Série Binarizada) indicando as tendências de valores de magnitude ao longo da Série de Entrada. Submetendo x_{bin} ao modelo treinado, as unidades visíveis são ajustadas (alteradas) para satisfazer ao padrão esperado pelo modelo, resultando em um vetor $x_{rec} = [1, 0, 0, 1, 0, 0, 0, 1, 0, 1, 0, 0, 1, 0, 0, \dots]$ (Série Binarizada Corrigida). Ao confrontarmos os elementos da Série Binarizada e a Série Binarizada Corrigida podemos verificar se a Série de Entrada está seguindo as tendências esperadas pelo modelo, bastando, para isso, identificar se, em cada tripla, há valores binários iguais a 1 na mesma posição em ambas Séries Binarizadas, ou seja, se ambas as triplas apresentam a mesma tendência. Caso isso seja positivo, então não há necessidade de ajustes, caso contrário, deve-se informar ao usuário as recomendações apresentadas na Série Binarizada Corrigida.

Embora o modelo contemple até a apresentação da Série Binarizada Corrigida, indicando os pontos que devem ser modificados para atender aos padrões do modelo, para esta tese foi implementada a reconstrução da série temporal baseada nas recomendações geradas. Esta reconstrução consiste em aplicar, de forma incremental, a soma (ou subtração) da diferença entre os elementos adjacentes da Série de Entrada para ao último elemento da Série de Saída com base na tendência sugerida pela Série Binarizada Corrigida. Este processo permite a geração de uma Série de Saída que reflete o comportamento esperado pelo modelo (tendências da Série Binarizada Corrigida). Na Seção 5 será apresentado como as Séries de Saídas são utilizadas para ajudar a calcular o ganho de se aplicar o método proposto para corrigir as execuções dos movimentos.

Exemplificando esse processo de reconstrução, temos que na Série de Entrada $x_0 = 0.7$ e $x_1 = 0.55$, durante a binarização temos que esta tripla indica uma tendência decrescente ($x_1 - x_0 = 0.55 - 0.7 = -0.15 \rightarrow x_{bin} = [1, 0, 0, \dots]$) ao aplicarmos a Série Binarizada ao modelo, é gerada uma recomendação de ajuste para esta tripla $x_{rec} = [0, 0, 1, \dots]$. Havendo esta divergência entre os elementos de x_{bin} e x_{rec} , segue-se a recomendação gerada pelo modelo, logo, sendo x' a Série de Saída ao início do processo iterativo de reconstrução a qual possui como único elemento o primeiro valor de magnitude da Série de Entrada ($x'_0 = x_0 = 0.7$) e sendo a recomendação uma tendência crescente (adição), então $x'_1 = x'_0 + |x_1 - x_0|$, ou seja $x'_1 = 0.7 + |-0.15| = 0.85$. Este processo se repete até que todos os elementos da série

original seja reconstruídos formando a Série de Saída $x' = [0.7, 0.85, 1.2, 1.2, 0.97, 0.83...]$ conforme ilustrado na Figura 4.5

4.5 Resumo

Neste capítulo foi descrito o método proposto por esta Tese para contornar o problema de pesquisa, apresentado no Capítulo 1, bem como a especificação e descrição dos componentes para execução das atividades descritas nos objetivos específicos. Apresentando inicialmente uma visão geral da proposta, foi possível especificar, na seções seguintes, como cada etapa corroborou para que o método proposto gerasse o modelo de reconhecimento e fornecesse recomendações de ajustes para correção do movimento executado. Além disso, também foi introduzido um método para seleção automatizado de amostras baseado na métrica magnitude, identificação estimada de centroides e cálculo para mapeamento dos sub-segmentos da série temporal que definem cada repetição do movimento e o processo de reconstrução da série temporal seguindo os ajustes recomendados pelo modelo.

Capítulo 5

Avaliação do Método Proposto

Este capítulo tem por objetivo descrever a validação da proposta de tese bem como apresentar os resultados e suas discussões, e para tal, são apresentadas as seguintes seções: (i) método de avaliação da proposta; (ii) resultados dos experimentos; e (iii) discussão dos resultados.

5.1 Método de avaliação

A avaliação do método proposto consistiu em usar uma base de dados pública chamada PHYTMO (Villa *et al.* 2022) para treinar os modelos, validar e testar suas capacidade em gerar sugestões de ajustes na execução de movimentos errados. Esta base contém dados brutos de sensores inerciais NGIMU (Technologies 2023) fixados nos braços (*arms*), antebraços (*forearms*), coxas (*thigh*) e perna (*shin*), em ambos os lados, esquerda (*left*) e direita (*right*), dos sujeitos.

Esta base fornece dados rotulados por grupos de idades dos sujeitos, exercícios, posição do sensor e se os movimentos foram executados corretamente ou incorretamente. Este conjunto de dados registrou 30 indivíduos agrupados em 5 faixas de idade — 22 a 26 (A), 30 a 39 (B), 42 a 49 (C), 50 a 55 (D) e 60 a 68 (E) — realizando, pelo menos 8 vezes, os seguintes exercícios: flex-extensão de joelhos (KFE); agachamento (SQT); abdução do quadril (HAA); flexão-extensão do cotovelo (EFE); extensão dos braços acima da cabeça (EAH); e apertar (SQZ).




Figura 5.1: Exemplos de dados de magnitude para: (a) Treinamento; (b) Validação; (c) e (d) Testes

Os dados brutos da base PHYTMO foram convertidos em séries de magnitude, seguindo o processo explicado na Seção 2.2, e esses arquivos foram utilizados para executar os experimentos para avaliar o método proposto. A Figura 5.1 representa uma amostra de dados, após a conversão dos dados brutos em séries de magnitude, para um único sensor, durante os 4 conjuntos de execução representados como séries temporais nas Figuras 5.1 a e b execuções corretas do movimento, e as nas Figuras 5.1 c e d execução incorreta do movimento, conforme indicado na documentação original da base de dados.

A Figura 5.2 apresenta o fluxograma de atividades realizadas no processo de validação do método proposto nesta Tese.

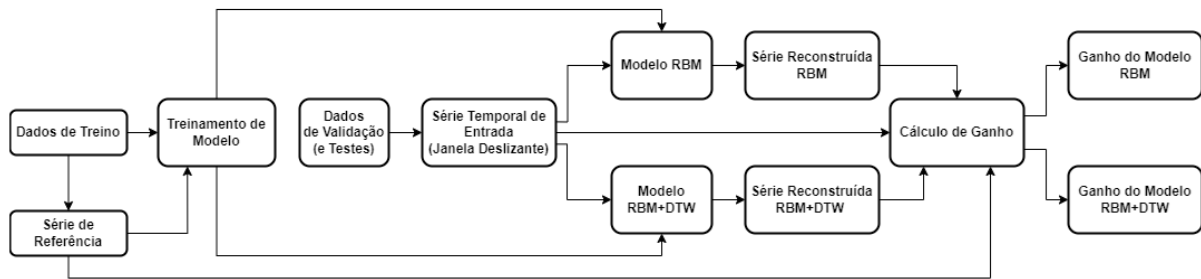


Figura 5.2: Fluxograma de avaliação do método proposto

Os dados associados à execução correta foram atribuídos para treinar (Figura 5.1 a) e validar (Figura 5.1 b) os modelos RBM e RBM+DTW, e os dados de execuções incorretas (Figura 5.1 c) e d) para testar. Optamos executar a validação utilizando séries temporais de execuções corretas, porém, não utilizadas no processo de treinamento, como mecanismo de estabelecermos um parâmetro de referência para a métrica ganho. Já para os testes foram utilizadas séries de execuções erradas que também não fizeram parte do treinamento para identificarmos a real capacidade do método proposto. Com base nessa distribuição, é possível mensurar os resultados da aplicação das recomendações sobre amostras de execução incorretas para cada segmento específico do órgão.

A métrica usada para mensurar o impacto da aplicação das sugestões é chamada de ganho. Ele usa o algoritmo *Dynamic Time Warping* (Seção 2.3) para identificar a distância das séries de entrada e a série de saída em relação a série de referência. Esta última é representada pela amostra que fornece o menor valor de distância média para as demais amostras (ver Seção 5.2.1). Vale ressaltar que esta métrica é utilizada exclusivamente para a validação do método proposto, não sendo parte do mesmo.

O ganho é dado por $G = (DTW(i, r) / DTW(o, r)) - 1$ onde $DTW(i, r)$ é a distância entre i (série de entrada original) e r (série de referência), $DTW(o, r)$ é a distância entre o (série de saída) e r , e -1 é o fator correção percentual. O resultado desta métrica indica o quão melhor ($G > 0$) ou pior ($G < 0$) a série de saída é em relação a série de entrada.

Podemos definir que o método proposto visa maximizar o valor da métrica ganho, porém, é importante esclarecer que o DTW é uma medida de distância a qual reflete o seguinte comportamento: quanto mais próxima de zero, mais similar são as séries comparadas, quanto mais distante de zero, mais diferente são as séries. Para exemplificarmos o comportamento

do ganho, supõe-se que temos uma série de entrada i onde $DTW(i, r) = 2,1$ e uma série de saída o cuja $DTW(o, r) = 0,7$. Para esta situação hipotética o ganho é dado por $G = (DTW(i, r) / DTW(o, r)) - 1 = (2,1 / 0,7) - 1 = 3 - 1 = 2$. Este resultado indica que a série de saída possui um ganho de 200% em relação a série de entrada, ou seja, ela está 2x mais próxima da série de referência que a série de entrada. Um segundo exemplo pode considerar $DTW(o, r) = 2,8$, então $G = 1 - (2,8 / 2,1) = 1 - 1,333 = -0,333$, ou seja, a série de saída é 33% pior (mais longe) em relação a série de referência que a série de entrada.

Além da definição da métrica ganho, também foram treinados dois modelos diferentes: (i) considerando todas as amostras automaticamente identificadas da série temporal de entrada, chamada de RBM; e (ii) RBM+DTW que consiste em gerar um modelo treinado com amostras que possuem distâncias menores ou iguais à distância média de todas as amostras identificadas da série temporal de entrada. Esta segunda abordagem visa gerar um modelo mais específico por utilizarem amostras mais similares uma das outras, implicando diretamente na qualidade das sugestões de ajustes e conseqüentemente nos ganhos obtidos por este modelo.

5.2 Resultados

Nesta seção descreveremos os resultados obtidos durante a execução dos experimentos sendo inicialmente apresentada uma amostra da obtenção da série de referência (Seção 5.2.1), seguido dos resultados obtidos durante a validação (Seção 5.2.2) e testes (Seção 5.2.3) dos modelos. Por último, na Seção 5.2.4, é apresentada uma discussão sobre os resultados obtidos.

5.2.1 Obtenção da série de referência

A Figura 5.1 exibe as amostras extraídas da série de treinamento (Figura 5.3) utilizando a técnica apresentada na Seção 4.2. Ao total foram identificadas 18 amostras bem definidas que foram usadas na etapa de treinamento dos modelos, outras duas amostras foram descartadas por estarem nos extremos da série temporal, impedindo-as de terem o mesmo tamanho que as demais. Cada amostra na Figura 5.3 representa uma execução correta do movimento.

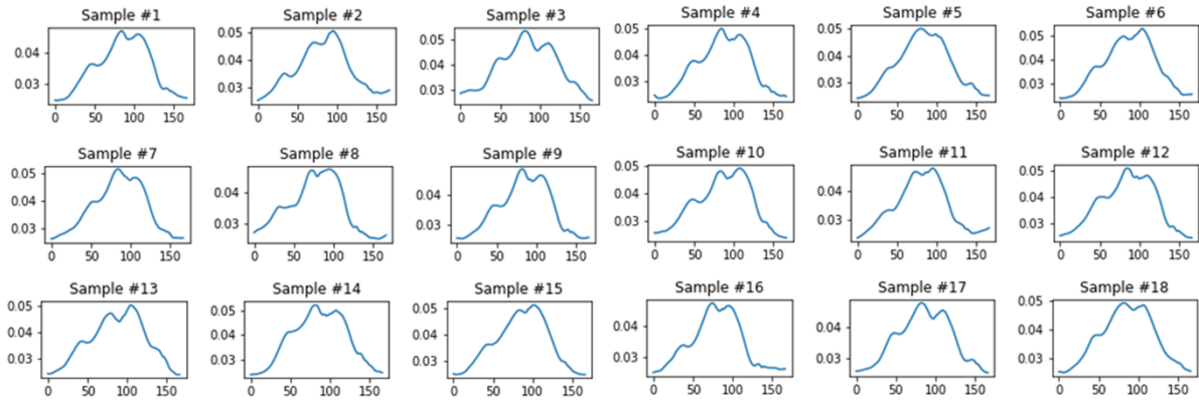


Figura 5.3: Amostras extraídas da série temporal de treinamento da Figura 5.1 a.

A obtenção da série de referência consiste em identificar a amostra que representa genericamente as demais, ou seja, a amostra mais semelhante às demais amostras da série temporal. Esta similaridade é obtida calculando a distância (DTW) entre os pares de todas as combinações de amostras. A Figura 5.4 apresenta a distância de cada amostra entre si, e a distância média de cada uma delas. É possível ver que a Amostra #3 tem o maior valor de distância média enquanto a Amostra #5 tem a menor distância média, sendo esta última (Amostra #5) ideal para ser a série de referência.

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12	#13	#14	#15	#16	#17	#18
#1	0	0,116012	0,212934	0,081604	0,07247	0,14899	0,127803	0,084122	0,040511	0,102565	0,057769	0,093089	0,089771	0,149693	0,113379	0,038214	0,05812	0,071287
#2	0,116012	0	0,124686	0,134002	0,074055	0,099281	0,069063	0,143369	0,10156	0,122024	0,125735	0,088387	0,09789	0,111101	0,095031	0,123127	0,099294	0,069248
#3	0,212934	0,124686	0	0,186713	0,141121	0,140095	0,080651	0,138278	0,163235	0,17362	0,188406	0,109602	0,179966	0,162766	0,141469	0,164747	0,180205	0,132188
#4	0,081604	0,134002	0,186713	0	0,060254	0,089798	0,117072	0,138855	0,078343	0,079004	0,074407	0,076014	0,073549	0,079045	0,063673	0,076771	0,115931	0,083728
#5	0,07247	0,074055	0,141121	0,060254	0	0,060734	0,061205	0,106907	0,054568	0,074683	0,064012	0,046228	0,064229	0,067814	0,041304	0,065057	0,075678	0,039148
#6	0,14899	0,099281	0,140095	0,089798	0,060734	0	0,07372	0,199803	0,106341	0,120545	0,115936	0,074533	0,081194	0,05852	0,047283	0,131089	0,152417	0,089181
#7	0,127803	0,069063	0,080651	0,117072	0,061205	0,07372	0	0,121042	0,083682	0,099423	0,107503	0,047224	0,09825	0,086779	0,067423	0,098897	0,091478	0,054044
#8	0,084122	0,143369	0,138278	0,138855	0,106907	0,199803	0,121042	0	0,069673	0,101515	0,069478	0,105539	0,124719	0,207186	0,153632	0,063221	0,076366	0,095913
#9	0,040511	0,10156	0,163235	0,078343	0,054568	0,106341	0,083682	0,069673	0	0,081588	0,065614	0,066284	0,093092	0,114324	0,079407	0,037847	0,057412	0,050529
#10	0,102565	0,122024	0,17362	0,079004	0,074683	0,120545	0,099423	0,101515	0,081588	0	0,084813	0,068209	0,062354	0,115445	0,076069	0,086289	0,093872	0,068014
#11	0,057769	0,125735	0,188406	0,074407	0,064012	0,115936	0,107503	0,069478	0,065614	0,084813	0	0,086766	0,077915	0,111201	0,095041	0,051414	0,07461	0,064981
#12	0,093089	0,088387	0,109602	0,076014	0,046228	0,074533	0,047224	0,105539	0,066284	0,068209	0,086766	0	0,072993	0,075469	0,043741	0,082929	0,085665	0,04905
#13	0,089771	0,09789	0,179966	0,073549	0,064229	0,081194	0,09825	0,124719	0,093092	0,062354	0,077915	0,072993	0	0,082966	0,059379	0,095819	0,118112	0,085911
#14	0,149693	0,111101	0,162766	0,079045	0,067814	0,05852	0,086779	0,207186	0,114324	0,115445	0,111201	0,075469	0,082966	0	0,055455	0,134995	0,151773	0,098165
#15	0,113379	0,095031	0,141469	0,063673	0,041304	0,047283	0,067423	0,153632	0,079407	0,076069	0,095041	0,043741	0,059379	0,055455	0	0,105599	0,115217	0,06746
#16	0,038214	0,123127	0,164747	0,076771	0,065057	0,131089	0,098897	0,063221	0,037847	0,086289	0,051414	0,082929	0,095819	0,134995	0,105599	0	0,06219	0,058255
#17	0,05812	0,099294	0,180205	0,115931	0,075678	0,152417	0,091478	0,076366	0,057412	0,093872	0,07461	0,085665	0,118112	0,151773	0,115217	0,06219	0	0,061255
#18	0,071287	0,069248	0,132188	0,083728	0,039148	0,089181	0,054044	0,095913	0,050529	0,068014	0,064981	0,04905	0,085911	0,098165	0,06746	0,058255	0,061255	0
AVG DTW	0,09213	0,099659	0,145593	0,089376	0,06497	0,099415	0,082514	0,11109	0,074667	0,089446	0,0842	0,070651	0,086562	0,103483	0,07892	0,082026	0,092755	0,068798

Figura 5.4: Matriz de distâncias entre amostras e distância média de amostra para as demais (AVG).

Vale ressaltar que na coluna #5, algumas amostras (#1, #2, #10, #14, #16 e #17) possuem distâncias maiores que a média. Essas amostras não são usadas para treinar o modelo RBM+DTW conforme apresentado ao final da Seção 5.1.

5.2.2 Resultados da Validação

Nesta etapa, utilizou-se as séries de validação (Figura 5.1 b) para avaliar se os modelos estão executando a recomendação de ajuste corretamente. A Figura 5.5 mostra a distância média para cada segmento. Este experimento avaliou mais de 24 mil repetições de exercícios físicos variados considerando todos os segmentos monitorados.

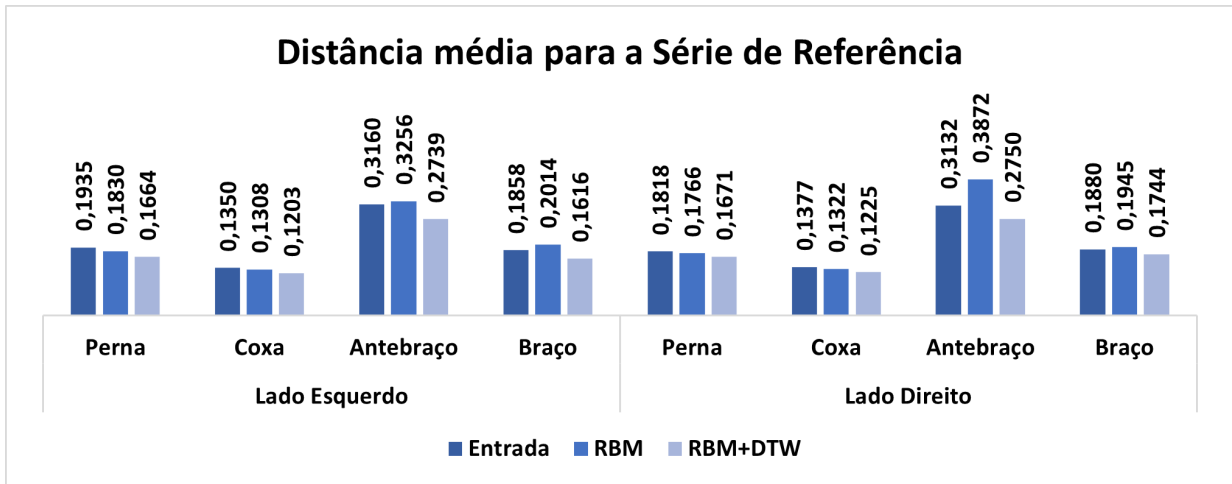


Figura 5.5: Distância média para a série de referência por modelo e segmento do corpo.

Como esperado, as distâncias da série de entrada à série de referência possuem valores maiores que as séries de saída para o modelo RBM+DTW. Isso significa que as sugestões geradas pelos modelos RBM+DTW levaram à mudanças que tornam a entrada mais semelhante à série de referência. Para o modelo RBM, é possível identificar que os segmentos superiores (braços e antebraços) de ambos os lados, apresentaram séries mais distantes que a entrada original, indicando que as sugestões afastaram a série de saída da série de referência. Avaliando os motivos desta situação, pudemos identificar as atividades físicas realizadas por pessoas do grupo E (mais idosos) não executaram a quantidade esperada de repetições (20), afetando diretamente a capacidade de estimar os centroides corretamente durante a seleção de amostras. Isso afetou diretamente a capacidade do método proposto em identificar apropriadamente as amostras ao longo da série temporal, conforme ilustrado na Figura 5.6.




Figura 5.6: Centroides identificados em uma série com menos repetições que o esperado

Com os centroides posicionados erroneamente devido a quantidade de repetições esperadas ser maior que a quantidade de repetições realizadas, o processo de seleção de amostras acabou por identificar amostras parciais do movimentos, que foram usadas para o treino do modelo RBM, afetando diretamente a qualidade dos feedbacks. Por outro lado, o RBM+DTW, através do processo de filtragem, conseguiu mesmo assim identificar padrões consistentes, descartando amostras incoerentes e gerando sugestões melhores que a série de entrada.

Além do problema da geração de modelos com dados de baixa qualidade, a Figura 5.7 apresenta um exemplo de um amostra que compara a série de entrada (Figura 5.7a), a série de saída RBM (Figura 5.7b) e a série de saída RBM+DTW (Figura 5.7c) à série de referência (linha azul em todas elas), onde as sugestões geraram saídas mais distantes da série de referência que a série de entrada. Ou seja, $G < 0$. Um outro motivo para a geração dessas séries de saídas com ganho negativo, dá-se pelo fato de que a série temporal de entrada já satisfaz a distribuição anterior aprendida pelos modelos, neste caso, quaisquer modificações podem afetar negativamente a qualidade de série produzida. A Figura 5.7 retrata esse comportamento, onde, a série de saída é mais distante da série de referência que a série de entrada, com percentuais de 13,73% ($G = (0,07046/0,08167) - 1 = 0,1373$) e 12,94% ($G = (0,07046/0,08093) - 1 = 0,1294$) para os modelos RBM e RBM+DTW respectivamente.




Figura 5.7: Exemplo de ganho negativo ($G < 0$): Comparação da Série de Referência em relação às séries: (a) Entrada, (b) Saída RBM e (c) Saída RBM+DTW.

Para casos como os representados pela Figura 5.7, não há necessidade de gerar recomendações de ajustes, ou seja, a entrada correta não precisa passar pelo modelo gerando ajustes que possam dar sugestões indesejadas. Esse critério pode ser aplicado de diferentes formas e deve ser uma decisão tomada durante a implementação da aplicação do modelo. Como exemplos destes critérios temos: (i) não gerar recomendações de séries de entrada que possuam uma distância menor ou igual a um limiar fixo; ou (ii) aplicar as sugestões apenas se o modelo sugerir um percentual mínimo de modificações.

Diferente da Figura 5.7, a Figura 5.8 apresenta resultados com séries mais próximas à série de referência que a entrada original, ou seja, $G > 0$. Neste exemplo, o modelo RBM gerou um ganho de 48,17% ($G = (0,06596/0,04512) - 1 = 0.4817$) e o modelo RBM+DTW gerou uma série de saída que tem um ganho de 32,38% ($G = (0,06596/0,04982) - 1 = 0.3238$) em comparação com a série de entrada, o que significa que ambos modelos foram capazes de produzir recomendações de qualidade. É importante destacar que, para este exemplo específico, o modelo RBM apresentou resultados melhores que o RBM+DTW. Isto ocorreu devido às sugestões do modelo RBM+DTW apresentarem um rigor maior sobre os ajustes que devem ser realizados em relação ao modelo RBM e, eventualmente, seu modelo podem interpretar tendências que não são expressas na série de referência, que busca ser mais genérica, assim como o modelo RBM.




Figura 5.8: Exemplo de ganho positivo ($G > 0$): Comparação da Série de Referência em relação às séries: (a) Entrada, (b) Saída RBM e (c) Saída RBM+DTW.

A Figura 5.9 mostra o ganho médio por segmento do corpo ao aplicar as sugestões do modelo. Os resultados mostram que RBM+DTW superou o modelo RBM, apresentando-se como um modelo mais preciso, produzindo sugestões de ajustes que foram mais bem sucedidas em reduzir a distância das séries de entrada para a série de referência, implicando diretamente em ganhos maiores.




Figura 5.9: Ganho médio por modelo e segmento.

Apesar da conclusão anterior, estes resultados não desqualificam o modelo RBM. Mesmo com o desempenho inferior aos modelos RBM+DTW, o modelo RBM ainda, em seu pior resultado (perna direita), tem um ganho médio de 48% em relação à série de entrada e no seu melhor resultado (coxa esquerda), ganhos de até 75%. Para o modelo RBM+DTW o

ganho médio para o pior e melhor resultados foram de 57% para a perna direita e 94% para a braço direito respectivamente.

Ao compararmos calcularmos a média geral por modelo, pudemos identificar que o RBM apresentou ganhos de 50.37% contra 73.25% do RBM+DTW, uma diferença mais de 20%, reflexo do processo de filtragem das séries usadas para o treinamento dos modelos. Vale ressaltar que as séries analisadas durante a validação são de execuções corretas dos exercícios, logo, é intuitivo esperar que o modelo não apresente tantas sugestões de ajustes. No geral, o processo de validação atendeu ao nosso propósito ao apresentar os resultados esperados na análise de dados de movimentação corretos.

5.2.3 Resultados dos Testes

Diferentemente do processo de validação, os experimentos de teste utilizaram dados de execução incorretos para avaliar os modelos, onde foram avaliados mais de 45 mil repetições de movimentos. A expectativa para este experimento foi de obter resultados melhores que os obtidos durante a validação, pois os modelos ajustariam as execuções incorretas, levando a ganhos ainda maiores.

Na Figura 5.10 é possível observar a tendência mostrada anteriormente no processo de validação, onde as séries de saída estão mais próximas da série de referência do que a entrada original, inclusive para o modelo RBM nos segmentos superiores (braços e antebraços).




Figura 5.10: Teste: Distância média por modelo para cada segmento.

Também é possível observar na Figura 5.10 que a média para as séries de entrada apresentam valores maiores que os apresentado na Figura 5.5. Esses resultados já eram esperados uma vez que os testes são realizados com séries de execuções erradas do movimento.

Os menores ganhos médios apresentados na Figura 5.11, é de 132% para (Perna Direita) e 148% (Coxa Direita) para o modelo RBM e RBM+DTW respectivamente. Já os maiores ganhos médios durante os testes foram de 201% para o RBM e de 229% para o RBM+DTW, ambos para o segmento da Coxa Esquerda. Foi possível notar também que o ganho médio para os segmentos do lado esquerdo do corpo foram ligeiramente maiores que os do lado direito, comportamento gerado pela falta de destreza com o lado não dominante (esquerdo) para a maioria dos sujeitos que realizaram os movimentos. Esses resultados expressam a eficiência em seguir as sugestões dos modelos. Isso significa que ambos os modelos geram séries de saída pelo menos duas vezes mais próximas à série de referência que a série de entrada.




Figura 5.11: Teste: Ganho médio por modelo para cada segmento.

Um exemplo de como ambos os modelos, RBM e RBM+DTW, corrigem a série de entrada pode ser observado na Figura 5.12. A série de entrada contém uma tendência decrescente no início e uma tendência crescente no final (Figura 5.12a). Estas tendências não existem nas séries de referência (Figura 5.12 - linha azul).




Figura 5.12: Testes: Comparação da Série de Referência em relação às séries: (a) Entrada, (b) Saída RBM e (c) Saída RBM+DTW.

Durante a geração da série de saída, o modelo RBM sugere ajuste corretos nas extremidades da série de entrada, porém gera uma distância maior entre os picos das séries (Figura 5.12 b) ao tentar recriar a oscilação no ponto intermediário do movimento. O modelo RBM+DTW ajusta corretamente as extremidades da série, porém obtêm melhores resultados ao preservar a distância entre os picos das séries (Figura 5.12 c). Este exemplo mostra que os modelos RBM geram uma série de saída 27,22% melhor (mais semelhante à série de referência) do que a série de entrada, contra os 84,89% da série de saída RBM+DTW.

Na Figura 5.13 é possível comparar o ganho de ambos os modelos por exercício e segmento corporal. Conforme explicado anteriormente, no geral, o RBM+DTW supera o RBM com ganhos maiores, sustentando a análise anterior.

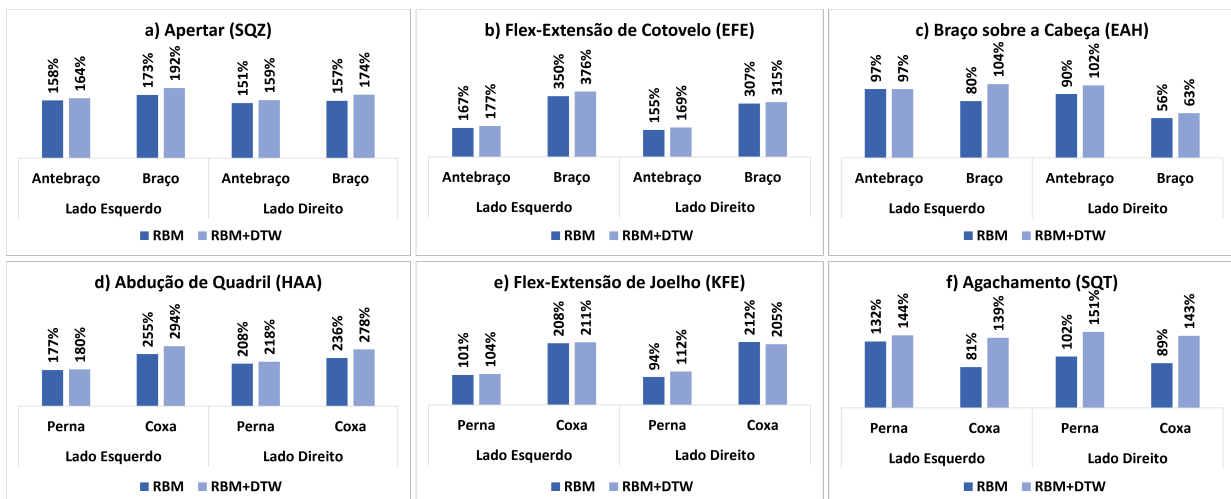


Figura 5.13: Testes: Ganho médio dos modelos para cada exercício por segmento.

Apesar da tendência do modelo RBM+DTW apresentar sugestões mais eficientes

que o modelo RBM, algumas exceções podem ser observadas. Essas exceções se deram devido a baixa amplitude do segmento durante a execução do movimento, ou seja, há pouca movimentação. O impacto disto pode ser observado na flex-extensão de joelho (Figura 5.13 e), onde os ganhos do modelo RBM superam os do RBM+DTW para a coxa direita. Neste caso, o modelo mais genérico (RBM) produziu sugestões ligeiramente melhores que o modelo mais específico (RBM+DTW) uma vez que o modelo do RBM tolera pequenas variações nos movimentos sem gerar recomendações de ajustes.

Os maiores valores de ganho para ambos os modelos foram obtidos durante o exercício de flex-extensão de cotovelo para o braço esquerdo, com 350% e 376% para os modelos RBM e RBM+DTW respectivamente. Já os menores valores de ganho médio foram de 56% (RBM) e 63% (RBM+DTW) para o braço direito na execução do movimento braço sobre a cabeça, valores significativamente menores que os demais exercícios. Tal comportamento é reflexo da geração do modelos usando amostras de baixa qualidade conforme explicado anteriormente durante a validação.

5.2.4 Discussão

Através dos resultados apresentados ao longo da Seção 5.2, foi possível responder as questões motivadoras desta tese, onde: (i) ao gerar um modelo de aprendizado de máquina utilizando uma Máquina Restrita de Boltzmann, a partir de uma série temporal binarizada, que representa o movimentos inerciais de cada segmento corporal, é possível indicar quais pontos, na série de entrada, não satisfazem os padrões de dados do processo de treinamento e corrigi-los de forma que se aproximem do padrão esperado pela rede neural; (ii) ao aplicar o modelo proposto a um banco de dados contendo dados inerciais de sujeitos realizando diversos exercícios físicos de forma correta e incorreta, foi possível treinar um modelo com os dados corretos e recomendar ajustes nas séries temporais dos dados incorretos, o que permitiu uma aumento de até 3,7 vezes na similaridade entre a série de entrada e a série de saída gerada pelo modelo de aprendizado de máquina; (iii) o método sugere a criação de modelos altamente específicos que possam identificar os padrões de movimento do usuário no início de cada exercício físico. Este recurso garante que o modelo que analisa as repetições subsequentes esteja o mais atualizado possível. Este método é flexível o suficiente para se adaptar a quaisquer atividades

físicas repetitivas.

Ao analisar os resultados foi possível identificar que apesar da utilização do DTW para encontrar uma série de referência entre a amostra de treinamento ter um alto custo computacional, este mecanismo apresenta vantagens relevantes quando utilizado como filtro para seleção das amostras para treinamento dos modelos. Conforme apresentado na Figura 5.11, o modelo RBM+DTW superou os ganhos do RBM para cada segmento. Usando notação *Big O* e considerando N como o número de amostras de tamanho n , temos que o custo computacional para identificarmos série de referência é igual ao custo de comparar $N * N$ amostras em que cada operação compara $n * n$ elementos de cada série temporal. Dessa forma, temos que o custo computacional desta operação é $O(N^2) * O(n^2)$.

Outra conclusão interessante dos resultados experimentais é que, eventualmente, a série de entrada já satisfaz o padrão aprendido pelos modelos durante o processo de treinamento. Neste caso, ambos os modelos RBM e RBM+DTW geram séries de saída ligeiramente diferentes das séries de entrada, o que pode aumentar a distância até a série de referência. Durante os experimentos, essas ocorrências foram consideradas para efeitos de validação dos modelos. Em uma aplicação prática, isso implica que é possível definir uma margem de tolerância ou quantidade mínima de recomendações de ajustes para que a série de fato recomende um ajuste ao usuário.

Uma terceira observação do experimento baseia-se no uso da métrica de magnitude, que se demonstra como um mecanismo eficaz para reduzir a dimensionalidade do modelo. Supondo que as leituras da IMU ocorram em uma frequência específica (ou seja, 10 Hz ou 10 leituras por segundo), é possível estimar a duração do movimento e sua velocidade observando a variação entre as leituras onde diferenças maiores significam movimentos mais rápidos e diferenças menores significam movimentos mais lentos.

Finalmente, um quarto *insight* desses experimentos é que, ao assumir o número de elementos na série de referência como o tamanho padrão da janela deslizante, é possível inferir uma série de entrada que não completa o movimento dentro desta janela como uma execução de movimento errada; esta suposição baseia-se no fato de que se o movimento não terminar ao longo do tamanho da janela, então ele foi executado muito lentamente. Por outro lado, múltiplas execuções dentro da mesma janela deslizante significam execuções rápidas, o que

também não satisfaz o padrão de treinamento.

5.2.5 Resumo

Nesta seção apresentou-se o método de avaliação da Tese proposta, a métrica utilizada para mensurar a qualidade do método proposto bem como os resultados dos experimentos. Por meio de uma base de dados pública foi possível treinar, validar e testar os modelos com dados reais de execuções de exercícios repetitivos. Através da métrica ganho, foi possível identificar o impacto em aplicar as recomendações sugeridas pelos diferentes modelos. Além disso, durante o processo de discussão de resultados foi possível identificar *insights* relevantes para a pesquisa, permitindo uma melhor das capacidades e limitações do método proposto.

Capítulo 6

Conclusão

O método proposto apresenta uma alternativa para avaliar atividades físicas repetitivas e fornecer sugestões de ajustes de movimento aos usuários através da criação de modelos altamente especializados para cada segmento corporal monitorado usando dados de sensores inerciais. Esta abordagem visa contornar as limitações das propostas atuais que geralmente buscam apenas classificar o tipo de movimento executado e/ou indicar se está sendo executado corretamente ou não. Além destas limitações, o método proposto também visa contornar as limitações de escopos dos modelos atuais, que exigem grande volumes de dados para e um longo processo de retreinamento do modelo para a inclusão de novas classes. Neste capítulo descreveremos as principais contribuições e limitações desta abordagem e, finalmente, apresentando as considerações finais desta pesquisa.

6.1 Contribuições

Ao empregar a métrica magnitude, que representa os valores absolutos das leituras dos sensores inerciais, fomos capazes de utilizar uma Máquina Restrita de Boltzmann para avaliar tendências de movimentos e fornecer sugestões para novas entradas que se desviassem dos padrões aprendidos no treinamento.

Diferentemente da classificação usual de redes neurais, esta abordagem visa ajustar os dados de entrada para uma saída que satisfaça o modelo RBM. As diferenças entre os dados de entrada e de saída indicam os pontos onde o movimento deve mudar para correta

execução da atividade física. O método proposto mitiga o problema de deslocamento do sensor, re-treinando o modelo com a posição atualizada do e assumindo valores absolutos independentemente da direção dos eixos no segmento do corpo. Este retreinamento possibilita o reposicionamento e/ou substituição de um ou vários sensores sempre que for necessário.

O retreinamento também possibilita a adaptação do modelo às novas condições físicas do usuário ao longo da prática da atividade, identificando novos padrões de ritmo e amplitude de movimento. Esta adaptação, que é representada como a generalização nos modelos de aprendizado profundo, possibilita a geração de feedbacks mais precisos aos usuários uma vez que o modelo re-treinado identifica quais os padrões produzidos durante a execução do movimento para aquela determinada sessão de treino. Essa característica permite ao usuário manter a qualidade do movimento executado mesmo que suas oscilações nas condições físicas variem ao longo da prática de exercícios.

Embora os resultados tenham mostrado que o uso de amostras não filtradas para gerar o modelo RBM produz sugestões menos precisas em comparação com RBM+DTW, esta abordagem ainda produziu séries que, em média, foram 2 vezes mais próximas (ou semelhantes) da série de referência do que a série de entrada. Em contrapartida, o modelo RBM+DTW gerou séries que foram até 3.7 vezes mais similares ao esperado do que a entrada original. Apesar do elevado custo computacional, $O(N^2) * O(n^2)$, devido ao processo de seleção de amostras para treinamento, o ganho apresentado por este modelo pode ser uma alternativa viável para aplicações que dispõe de recursos computacionais suficientes para tal.

Outra contribuição desta abordagem é a flexibilidade em se adaptar a qualquer movimento repetitivo. Por seu treinamento ser realizado em tempo de execução, ou seja, ao início de cada atividade física diferente, o modelo atua exclusivamente avaliando os dados inerciais produzidos para o movimento realizado durante o treinamento, sendo sobrescrito sempre que um novo treinamento é realizado. Isso garante a atualização do modelo sempre que uma atividade física for realizada

Adicionalmente, o método de seleção automatizado de amostras, que consiste em usar um limiar para agrupar valores que compõem uma única amostra ao longo da série temporal, mostrou-se eficiente. Esta abordagem, apesar de trabalhar com estimativas, permitiu identificar adequadamente as amostras que representam repetições individuais da atividade

física. Tendo como referência apenas o número de repetições durante a série, foi possível estimar o ponto médio de cada repetição e, baseado na distância média entre esses pontos médios (centroides), estimar o comprimento médio do segmento que contém os dados de uma repetição sendo executada. Isso permitiu a exclusão de amostras incompletas nos extremos da série temporal, bem como a identificação de variações do intervalo de tempo das execuções individuais ao sobrepor amostras de mesmo tamanho.

6.2 Limitações

O ponto mais crítico desta abordagem recai sobre a geração de amostras de qualidade (execuções corretas do movimento) para treinamento do modelo. Esta etapa, quando não executada de forma apropriada, incidirá diretamente na qualidade dos feedbacks produzidos pelos modelos.

A aplicação desta metodologia em um cenário real exige um profissional responsável para garantir a qualidade dos dados produzidos durante o treinamento do modelo, ou seja, o profissional deve garantir que durante a série de treinamento os movimentos sejam executados corretamente. Nesse sentido, o usuário deve assimilar a execução correta da atividade física e tentar repeti-la da melhor forma possível de acordo com a orientação profissional. Caso um movimento errado seja usado para treinar o modelo, as recomendações podem apresentar resultados incoerentes, sugerindo ajustes que induzem o usuário a executar o movimento similar ao movimento incorretamente executado durante o treinamento.

Outro desafio desta abordagem é definir quando uma série de entrada deve ser analisada pelo modelo. Não é adequado, nem prático, submeter uma série ao modelo a cada nova leitura do sensor. O critério utilizado nesta tese é o valor máximo na janela deslizante quando atinge o mesmo índice que o valor máximo na série de referência, então a série de entrada é binarizada e submetida ao modelo para avaliação. Apesar disto, esta abordagem ainda pode tentar avaliar séries temporais que não representem os dados de uma execução, gerando feedbacks desnecessários, exemplo, dados lidos no intervalo entre duas repetições.

Apesar da métrica magnitude eliminar a necessidade de posicionar os sensores sempre em uma mesma orientação específica, a mesma também suprime a capacidade de identificar

a orientação e os ângulos do movimento. A redução de dimensionalidade e a obtenção dos valores absolutos exercidos sobre o sensor inviabilizam o cálculo que, por um lado, poderiam melhorar ainda mais a qualidade do feedback dado aos usuários, e por outro exigir mais poder de processamento e recursos do hardware que implementa o método proposto.

6.3 Considerações Finais

Até onde sabemos, a literatura não possui soluções adequadas para resolver o problema de fornecer *feedback* qualitativo para ajudar os usuários a melhorar seus movimentos físicos, sendo este o principal, porém não o único, diferencial do método proposto nesta tese.

Expandindo limites do estado da arte no reconhecimento da atividade humana, estudos como os citados no Capítulo 3 apresentam contribuições significativas através de redes neurais profundas, análise de séries temporais, até mesmo fusão de dados de múltiplas fontes para aprimorar os modelos de reconhecimento. No entanto estes métodos concentram-se no reconhecimento de ações ou movimentos específicos (pré-treinados) sem oferecer *feedback* para ajudar os usuários a corrigir um movimento errado e a corrigi-lo. Apesar do uso de grandes bases de dados combinadas ao processo generalização durante a geração do modelos serem eficientes para o reconhecimento de um movimento, seja correto ou incorreto, esta técnica ainda não é capaz de se adequar aos ritmos particulares dos usuários a ponto de oferecer *feedbacks* que os ajudem a executar os movimentos corretamente, tão pouco é capaz de identificar e avaliar movimentos que nunca foram usados no processo de treinamento, limitando essas abordagens a um cenário estático.

O modelo proposto não só oferece *feedbacks* de ajustes, mas também é capaz de aprender padrões de novos movimentos a partir de um conjunto de amostras reduzidas, geradas em tempo de execução. Essa característica amplia as possíveis aplicações deste modelos, viabilizando-o para uso em academias, fisioterapias, monitoramento de equipamentos entre outras abordagens. No contexto das academias, uma aplicação prática poderá auxiliar o profissional qualificado a dar assistência a vários usuários de forma simultânea e, por que não, avaliação remota destes usuários.

Como resultado desta pesquisa, foram realizada duas publicações em periódicos re-

levantantes: (i) *An Online Method for Supporting and Monitoring Repetitive Physical Activities Based on Restricted Boltzmann Machines* (Alencar, Barreto, Souto e Oliveira 2023) a qual apresenta os resultados obtidos nesta tese; e (ii) *Embedded Restricted Boltzmann Machine Approach for Adjustments of Repetitive Physical Activities Using IMU Data* (Alencar, Barreto, Oliveira e Souto 2023) a qual é uma aplicação do modelo proposto nesta tese a qual oferece sugestões de ajustes quanto a intensidade, velocidade e amplitude do movimento executado.

Finalmente, estudos adicionais poderiam combinar múltiplas sugestões de cada sensor de segmento como um único. Ao combinar estes múltiplos resultados num feedback único, é possível avaliar um sistema complexo utilizando avaliações menores como uma abordagem de dividir para conquistar. Além deste, uma possível otimização do modelo pode ser feita através da aplicação do algoritmo de *Gaussian-Bernoulli Restricted Boltzmann Machine* que permite o uso de valores reais na camada de entrada, evitando o processo de binarização e produzindo ajustes com precisões reais das séries temporais.

6.4 Trabalhos futuros

Durante o desenvolvimento da tese foi possível identificar alguns pontos que merecem uma análise mais profunda, abrindo margem para a continuidade das pesquisas nesta área, tais como:

- **Aplicação em cenário real:** Desenvolver um hardware capaz de embarcar o método proposto e confrontar as sugestões produzidas pelo modelos com as sugeridas por um terceiro profissional qualificado.
- **Utilizar Gaussian-Bernoulli Restricted Boltzmann Machines:** Esta abordagem permite o uso de valores reais na camada de entrada da RBM ao invés de valores binários.
- **Atividades físicas não repetitivas:** Testar a viabilidade de usar ou adaptar o método para monitorar atividades físicas que não regressam à posição inicial, ou seja, que são finalizados no ápice do movimento - ex.: *jerk*, *split jerk*

-
- **Apresentação de feedbacks:** Apresentar um método para combinar os feedbacks individuais, de cada segmento corporal, em uma informação sucinta para o usuário.

Referências Bibliográficas

- Abdel-Basset, M., Hawash, H., Chakraborty, R., Ryan, M., Elhoseny, M. e Song, H. (2021), St-deepfar: Deep learning model for human activity recognition in iohr applications, *IEEE Internet of Things Journal* 8(6), 4969–4979.
- Alencar, M., Barreto, R., Oliveira, H. e Souto, E. (2023), Embedded restricted boltzmann machine approach for adjustments of repetitive physical activities using imu data, *IEEE Embedded Systems Letters* pp. 1–1.
- Alencar, M., Barreto, R., Souto, E. e Oliveira, H. (2023), An online method for supporting and monitoring repetitive physical activities based on restricted boltzmann machines, *Journal of Sensor and Actuator Networks* 12(5). URL : <https://www.mdpi.com/2224-2708/12/5/70>
- Anguita, D., Ghio, A., Oneto, L., Parra, X. e Reyes-Ortiz, J. (2012), Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine, *in Ambient Assist. Living Home Care*, Vol. 7657, pp. 216–223.
- Ansari, M., Mahmood, N., Nadeem, A., Mehmood, A. e Rizwan, K. (2017), Fall detection system for the elderly based on the classification of shimmer sensor prototype data, *Healthcare Informatics Research* 23, 147–158.
- Baños, O., Damas, M., Pomares, H., Rojas, I., Tóth, M. A. e Amft, O. (2012), A benchmark dataset to evaluate sensor displacement in activity recognition, *in Proceedings of the 2012 ACM Conference on Ubiquitous Computing, UbiComp '12*, Association for Computing Machinery, New York, NY, USA, p. 1026–1035. URL : <https://doi.org/10.1145/2370216.2370437>

- Badar ud din Tahir, S., Jalal, A. e Batool, M. (2020), Wearable sensors for activity analysis using smo-based random forest over smart home and sports datasets, *in* 2020 3rd International Conference on Advancements in Computational Sciences (ICACS), pp. 1–6.
- Banos, O., Garcia, R., Holgado-Terriza, J. A., Damas, M., Pomares, H., Rojas, I., Saez, A. e Villalonga, C. (2014), mhealthdroid: A novel framework for agile development of mobile health applications, *in* L. Pecchia, L. L. Chen, C. Nugent e J. Bravo, eds, Ambient Assisted Living and Daily Activities, Springer International Publishing, Cham, pp. 91–98.
- Bhat, G., Tran, N., Shill, H. e Ogras, U. (2020), w-har: An activity recognition dataset and framework using low-power wearable devices, *Sensors (Basel, Switzerland)* 20.
- Bijalwan, V., Semwal, V., Singh, G. e Mandal, T. (2022), Hdl-psr: Modelling spatio-temporal features using hybrid deep learning approach for post-stroke rehabilitation, *Neural Processing Letters* 54.
- Brenna, S., Minotti, P., Bonfanti, A., Laghi, G., Langfelder, G., Longoni, A. e Lacaita, A. (2015), A low-noise sub-500 microwatt lorentz force based integrated magnetic field sensing system, *Proceedings of the IEEE International Conference on Micro Electro Mechanical Systems (MEMS)* 2015, 932–935.
- Bächlin, M., Plotnik, M., Roggen, D., Maidan, I., Hausdorff, J., Giladi, N. e Troster, G. (2010), Wearable assistant for parkinson’s disease patients with the freezing of gait symptom, *Information Technology in Biomedicine, IEEE Transactions on* 14, 436 – 446.
- Casilari, E., Santoyo-Ramón, J. A. e Cano-García, J. M. (2017), Umafall: A multisensor dataset for the research on automatic fall detection, *Procedia Computer Science* 110, 32–39. 14th International Conference on Mobile Systems and Pervasive Computing (MobiSPC 2017) / 12th International Conference on Future Networks and Communications (FNC 2017) / Affiliated Workshops. URL : <https://www.sciencedirect.com/science/article/pii/S1877050917312899>
- Chavarriaga, R., Sagha, H., Calatroni, A., Digumarti, S. T., Tröster, G., del R. Millán, J. e Roggen, D. (2013), The opportunity challenge: A benchmark

- database for on-body sensor-based activity recognition, *Pattern Recognition Letters* 34(15), 2033–2042. Smart Approaches for Human Action Recognition. URL : <https://www.sciencedirect.com/science/article/pii/S0167865512004205>
- Chen, C., Jafari, R. e Kehtarnavaz, N. (2015), Utd-mhad: A multimodal dataset for human action recognition utilizing a depth camera and a wearable inertial sensor, *in* 2015 IEEE International Conference on Image Processing (ICIP), pp. 168–172.
- Chen, K.-Y., Shin, J., Hasan, M. A. M., Liaw, J.-J., Yuichi, O. e Tomioka, Y. (2022a), Fitness movement types and completeness detection using a transfer-learning-based deep neural network, *Sensors* 22(15). URL : <https://www.mdpi.com/1424-8220/22/15/5700>
- Chen, K.-Y., Shin, J., Hasan, M. A. M., Liaw, J.-J., Yuichi, O. e Tomioka, Y. (2022b), Fitness movement types and completeness detection using a transfer-learning-based deep neural network, *Sensors* 22(15). URL : <https://www.mdpi.com/1424-8220/22/15/5700>
- Chereshnev, R. e Kertész-Farkas, A. (2018), Hugadb: Human gait database for activity recognition from wearable inertial sensor networks, *in* W. M. van der Aalst, D. I. Ignatov, M. Khachay, S. O. Kuznetsov, V. Lempitsky, I. A. Lomazova, N. Loukachevitch, A. Napoli, A. Panchenko, P. M. Pardalos, A. V. Savchenko e S. Wasserman, eds, *Analysis of Images, Social Networks and Texts*, Springer International Publishing, Cham, pp. 131–141.
- Conforti, I., Mileti, I., Del Prete, Z. e Palermo, E. (2020), Measuring biomechanical risk in lifting load tasks through wearable system and machine-learning approach, *Sensors* 20, 1557.
- Devices, A. (2007), Documentação adxl330, <https://www.analog.com/media/en/technical-documentation/data-sheets/ADXL330.pdf>. Acessado em 11/11/2021.
- Dua, N., Singh, S. N., Semwal, V. B. e Challa, S. K. (2023), Inception inspired cnn-gru hybrid network for human activity recognition, *Multimedia Tools and Applications* 82(4), 5369–5403. URL : <https://doi.org/10.1007/s11042-021-11885-x>
- Forster, K., Roggen, D. e Troster, G. (2009), Unsupervised classifier self-calibration through

- repeated context occurrences: Is there robustness against sensor displacement to gain?, *in* 2009 International Symposium on Wearable Computers, pp. 77–84.
- Freire-Obregón, D., Lorenzo-Navarro, J., Santana, O. J., Hernández-Sosa, D. e Castrillón-Santana, M. (2023), An x3d neural network analysis for runner’s performance assessment in a wild sporting environment, *in* 2023 18th International Conference on Machine Vision and Applications (MVA), pp. 1–5.
- Fuller, D., Ferber, R. e Stanley, K. (2022), Why machine learning (ml) has failed physical activity research and how we can improve, *BMJ Open Sport & Exercise Medicine* 8, e001259.
- Hinton, G. E. (2007), Boltzmann machines. URL : <https://www.cs.toronto.edu/hinton/csc321/readings/boltz321.pdf>
- Huamin, T., Qiuqun, D. e Shanzhu, X. (2020), Reconstruction of time series with missing value using 2d representation-based denoising autoencoder, *Journal of Systems Engineering and Electronics* 31(6), 1087–1096.
- Huang, M. e Clancy, E. (2022), Smart walker: an imu-based device for patient activity logging and fall detection, *in* 2022 IEEE Signal Processing in Medicine and Biology Symposium (SPMB), pp. 1–4.
- IMU Axis References* (2021), <https://aws1.discourse-cdn.com/arduino/original/4X/c/8/5/c85eafee44c4322593102ecc74bf387cae2eee5b.png>. Acessado em 11/11/2021.
- Inversense (2012), Documentação gy-521, <http://www.haoyuelectronics.com/Attachment/GY-521/mpu6050.pdf>. Acessado em 11/11/2021.
- Inversense (2013), Documentação mpu-6500, <https://octopart.com/datasheet/mpu-6500-invensense-30535670>. Acessado em 11/11/2021.
- Inversense (2014), Documentação mpu-9250, <https://octopart.com/datasheet/mpu-9250-invensense-33342822>. Acessado em 11/11/2021.
- Jalal, A., Batool, M. e Kim, K. (2020), Stochastic recognition of physical activity and healthcare using tri-axial inertial wearable sensors, *Applied Sciences* 10, 7122.

- Jalal, A., Quaid, M. A. K. e Sidduqi, M. A. (2019), A triaxial acceleration-based human motion detection for ambient smart home system, *in* 2019 16th International Bhurban Conference on Applied Sciences and Technology (IBCAST), pp. 353–358.
- Khimraj, Shukla, P., Vijayvargiya, A. e Kumar, R. (2020), Human activity recognition using accelerometer and gyroscope data from smartphones, *in* Proceedings - 2020 International Conference on Emerging Trends in Communication, Control and Computing, ICONC3 2020.
- Kim, D.-E., Mai, N.-D. e Han, D. S. (2023), On-device deep learning-based multiple behavior detection using imu motion sensors, *in* 2023 Fourteenth International Conference on Ubiquitous and Future Networks (ICUFN), pp. 194–197.
- Kionix (2019), Documentação kxtf9, <https://www.kionix.com/product/KXTF9-2050>. Acessado em 11/11/2021.
- Kiprijanovska, I., Panchevski, F., Stankoski, S., Gjoreski, M., Archer, J., Broulidakis, J., Mavridou, I., Hayes, B., Guerreiro, T., Nduka, C. e Gjoreski, H. (2023), Smart glasses for gait analysis of parkinson’s disease patients, *in* 2023 46th MIPRO ICT and Electronics Convention (MIPRO), pp. 385–390.
- Kwolek, B. e Kepski, M. (2014), Human fall detection on embedded platform using depth maps and wireless accelerometer, *Computer Methods and Programs in Biomedicine* 117(3), 489–501. URL : <https://www.sciencedirect.com/science/article/pii/S0169260714003447>
- la Torre, F. D., Hodgins, J., Bargteil, A., Martin, X., Macey, J., Collado, A. e Beltran, P. (2008), Guide to the carnegie mellon university multimodal activity (cmu-mmact) database. URL : <http://kitchen.cs.cmu.edu/main.php>
- Li, W., Han, M. e Wang, J. (2020), Recurrent restricted boltzmann machine for chaotic time-series prediction, *in* 2020 12th International Conference on Advanced Computational Intelligence (ICACI), pp. 439–445.

- Li, Y., Hu, H., Zhu, Z. e Zhou, G. (2020), Scanet: Sensor-based continuous authentication with two-stream convolutional neural networks, *ACM Transactions on Sensor Networks* 16(3).
- Liao, Y., Vakanski, A. e Xian, M. (2020), A deep learning framework for assessing physical rehabilitation exercises, *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 28(2), 468–477.
- Lima, W. S., Bragança, H. L. e Souto, E. J. (2021), Nohar - novelty discrete data stream for human activity recognition based on smartphones with inertial sensors, *Expert Systems with Applications* 166, 114093. URL : <https://www.sciencedirect.com/science/article/pii/S0957417420308484>
- Malekzadeh, M., Clegg, R. G., Cavallaro, A. e Haddadi, H. (2018), Protecting sensory data against sensitive inferences, *in Proceedings of the 1st Workshop on Privacy by Design in Distributed Systems, W-P2DS'18*, ACM, New York, NY, USA, pp. 2:1–2:6. URL : <http://doi.acm.org/10.1145/3195258.3195260>
- Manimaran, M., Sasi Kumar, A., Natteshan, N. V. S., Baranitharan, K., Mahaveerakannan, R. e Sudhakar, K. (2023), Detecting the human activities of aging people using restricted boltzmann machines with deep learning technique in iot, *in 2023 Third International Conference on Artificial Intelligence and Smart Energy (ICAIS)*, pp. 105–110.
- Maskeliūnas, R., Damaševičius, R., Blažauskas, T., Canbulut, C., Adomavičienė, A. e Griškevičius, J. (2023), Biomacvr: A virtual reality-based system for precise human posture and motion analysis in rehabilitation exercises using depth sensors, *Electronics* 12(2). URL : <https://www.mdpi.com/2079-9292/12/2/339>
- Miners, M. (2021), Documentação motionminers, <https://www.motionminers.com/mmts?lang=en>. Acessado em 11/11/2021.
- Montull, L., Slapšinskaitė-Dackevičienė, A., Kiely, J., Hristovski, R. e Balagué, N. (2022), Integrative proposals of sports monitoring: Subjective outperforms objective monitoring, *Sports Medicine - Open* 8.

- Nadaf, A. e Pardeshi, S. (2023), Classifying sign language gestures using decision trees: A comparison of semg and imu sensor data, *in* 2023 4th International Conference for Emerging Technology (INCET), pp. 1–8.
- Ngo, T. T., Makihara, Y., Nagahara, H., Mukaigawa, Y. e Yagi, Y. (2014), The largest inertial sensor-based gait database and performance evaluation of gait-based personal authentication, *Pattern Recognition* 47(1), 228–237. URL : <https://www.sciencedirect.com/science/article/pii/S003132031300280X>
- Niemann, F., Reining, C., Moya Rueda, F., Nair, N. R., Steffens, J. A., Fink, G. A. e ten Hompel, M. (2020), Lara: Creating a dataset for human activity recognition in logistics using semantic attributes, *Sensors* 20(15). URL : <https://www.mdpi.com/1424-8220/20/15/4083>
- Papamichail, M. D., Chatzidimitriou, K. C., Karanikiotis, T., Oikonomou, N.-C. I., Symeonidis, A. L. e Saripalle, S. K. (2019), Brainrun: A behavioral biometrics dataset towards continuous implicit authentication, *Data* 4(2). URL : <https://www.mdpi.com/2306-5729/4/2/60>
- Permatasari, J., Connie, T. e Song, O. T. (2020), The mmuisd gait database and performance evaluation compared to public inertial sensor gait databases, *in* R. Alfred, Y. Lim, H. Haviluddin e C. K. On, eds, Computational Science and Technology, Springer Singapore, Singapore, pp. 189–198.
- Perumal, T., Ramanujam, E., Suman, S., Sharma, A. e Singhal, H. (2023), Internet of things centric-based multiactivity recognition in smart home environment, *IEEE Internet of Things Journal* 10(2), 1724–1732.
- Reiss, A. e Stricker, D. (2012), Introducing a new benchmarked dataset for activity monitoring, *in* 2012 16th International Symposium on Wearable Computers, pp. 108–109.
- Saha, S. S., Rahman, S., Rasna, M. J., Mahfuzul Islam, A. e Rahman Ahad, M. A. (2018), Du-md: An open-source human action dataset for ubiquitous wearable sensors, *in* 2018 Joint 7th International Conference on Informatics, Electronics Vision (ICIEV) and 2018

- 2nd International Conference on Imaging, Vision Pattern Recognition (icIVPR), pp. 567–572.
- Sakoe, H. e Chiba, S. (1978), Dynamic programming algorithm optimization for spoken word recognition, *IEEE Transactions on Acoustics, Speech, and Signal Processing* 26, 159–165.
- Saleh, M., Abbas, M. e Le Jeannes, R. (2021), FallAllD: An Open Dataset of Human Falls and Activities of Daily Living for Classical and Deep Learning Applications, *IEEE Sensors Journal* 21(2), 1849–1858. URL : <https://hal.archives-ouvertes.fr/hal-03102536>
- Semwal, V., Gupta, A. e Lalwani, P. (2021), An optimized hybrid deep learning model using ensemble learning approach for human walking activities recognition, *The Journal of Supercomputing* 77.
- Seo, K. (2023), Real-time estimation of walking speed and stride length using an imu embedded in a robotic hip exoskeleton, in 2023 IEEE International Conference on Robotics and Automation (ICRA), pp. 12665–12671.
- Sherin Zebiah, S., Shalomy, A. V., Kachhap, J., Tete, N., Nancy, R., Ananthi, A., Prasanna, J., Subathra, M. e George, S. (2023), Human fall detection using machine learning and deep learning techniques: A survey, in 2023 4th International Conference on Signal Processing and Communication (ICSPC), pp. 253–257.
- Shi, S., Wang, Y., Dong, H., Gui, G. e Ohtsuki, T. (2022), Smartphone-aided human activity recognition method using residual multi-layer perceptron, in IEEE INFOCOM 2022 - IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS), pp. 1–6.
- Shoaib, M., Bosch, S., Incel, O. D., Scholten, H. e Havinga, P. J. M. (2014), Fusion of smartphone motion sensors for physical activity recognition, *Sensors* 14(6), 10146–10176. URL : <https://www.mdpi.com/1424-8220/14/6/10146>
- Sikder, N. e Nahid, A.-A. (2021), Ku-har: An open dataset for heterogeneous human activity recognition, *Pattern Recognition Letters* 146, 46–54. URL : <https://www.sciencedirect.com/science/article/pii/S0167865521000933>

- Smolensky, P. (1986), Information processing in dynamical systems: Foundations of harmony theory, *Parallel Distributed Process* 1.
- Sony (2016), Documentação ps move, https://manuals.playstation.net/document/pdf/CECH-ZCM1GY_1.pdf. Acessado em 11/11/2021.
- Stisen, A., Blunck, H., Bhattacharya, S., Prentow, T. S., Kjærgaard, M. B., Dey, A., Sonne, T. e Jensen, M. M. (2015), Smart devices are different: Assessing and mitigating mobile sensing heterogeneities for activity recognition, *in* Proceedings of the 13th ACM Conference on Embedded Networked Sensor Systems, SenSys '15, Association for Computing Machinery, New York, NY, USA, p. 127–140. URL : <https://doi.org/10.1145/2809695.2809718>
- STMicroelectronics (2011), Documentação lis2dh, <https://pdf1.alldatasheet.com/datasheet-pdf/view/500168/STMICROELECTRONICS/LIS2DH.html>. Acessado em 11/11/2021.
- STMicroelectronics (2012), Documentação lsm330dlc, <https://pdf1.alldatasheet.com/datasheet-pdf/view/509335/STMICROELECTRONICS/LSM330DLC.html>. Acessado em 11/11/2021.
- STMicroelectronics (2015), Documentação lsm9ds1, <https://www.st.com/resource/en/datasheet/lsm9ds1.pdf>. Acessado em 11/11/2021.
- Strain, M. (2020), Documentação 3dm-gx1, https://www.microstrain.com/inertial/3DM-GX1?qt-product_quicktab=1#qt-product_quicktab. Acessado em 11/11/2021.
- Sun, C.-M., Tsai, M.-H., Liu, Y.-C. e Fang, W. (2010), Implementation of a monolithic single proof-mass tri-axis accelerometer using cmos-mems technique, *Electron Devices, IEEE Transactions on* 57, 1670 – 1679.
- Sztyler, T. (2019), Sensor-based human activity recognition: Overcoming issues in a real world setting, PhD thesis, Universität Mannheim, Mannheim, Germany. <http://ub-madoc.bib.uni-mannheim.de/49914/>.

- Tao, S., Goh, W. L. e Gao, Y. (2023), A convolved self-attention model for imu-based gait detection and human activity recognition, *in* 2023 IEEE 5th International Conference on Artificial Intelligence Circuits and Systems (AICAS), pp. 1–5.
- Tavenard, R. (2021), An introduction to dynamic time warping. URL : <https://rtavenar.github.io/blog/dtw.html>
- Technologies, E. E. S. (2021), Documentação inertiacube3, <https://est-kl.com/manufacturer/intersense/wireless-inertiacube-3.html>. Acessado em 11/11/2021.
- Technologies, X.-I. (2023), NGIMU - Wearable sensor, <https://x-io.co.uk/ngimu/>. [Online; accessed 15-May-2023].
- Thiam, T. (1999), The boltzmann machine, *in* IJCNN'99. International Joint Conference on Neural Networks. Proceedings (Cat. No.99CH36339), Vol. 6, pp. 4428–4431 vol.6.
- Trevisio (2021), Documentação colibri trevisio, <https://est-kl.com/manufacturer/trivisio/colibri-wireless.html>. Acessado em 11/11/2021.
- VanBibber, H. D., Moyal, A. J., Geletka, B. J., Drummond, C. K., Patel, S. R., Calcei, J. G., Voos, J. E. e Seshadri, D. R. (2023), Wearable technology to quantify patient reported outcome measures to guide rehabilitation following anterior cruciate ligament reconstruction, *in* 2023 IEEE International Conference on Digital Health (ICDH), pp. 356–358.
- Vavoulas, G., Chatzaki, C., Malliotakis, T., Padiaditis, M. e Tsiknakis, M. (2016), The mobi-act dataset: Recognition of activities of daily living using smartphones, *in* ICT4AgeingWell.
- Verma, A., Semwal, V. B. e Kumar Singh, K. (2021), Development of universal polynomial equation for all the sub-phases of human gait, *in* M. K. Bajpai, K. Kumar Singh e G. Giakos, eds, Machine Vision and Augmented Intelligence—Theory and Applications, Springer Singapore, Singapore, pp. 45–55.
- Villa, S. G., Parra, A. M., Martín, A. J., Domínguez, J. J. G. e Casillas-Perez, D. (2021), MI algorithms for the assessment of prescribed physical exercises, *in* 2021 IEEE International Symposium on Medical Measurements and Applications (MeMeA), pp. 1–6.

- Villa, S., Jiménez Martín, A. e García, J. (2022), A database of physical therapy exercises with variability of execution collected by wearable sensors, *Scientific Data* 9.
- Vintsyuk, T. K. (1968), Speech discrimination by dynamic programming, *Cybernetics* 4, 52–57.
- Vishal, M. (2016), Motion sensor technology and applications overview, <https://invensense.tdk.com/wp-content/uploads/2016/11/Motion-Sensor-Technology-and-Applications-Overview-10-20-16-V1.pdf>. Acessado em 19/10/2021.
- Wang, Z., Zhao, T., Ma, J., Chen, H., Liu, K., Shao, H., Wang, Q. e Ren, J. (2022), Hear sign language: A real-time end-to-end sign language recognition system, *IEEE Transactions on Mobile Computing* 21(7), 2398–2410.
- Weiss, G. M., Yoneda, K. e Hayajneh, T. (2019), Smartphone and smartwatch-based biometrics using activities of daily living, *IEEE Access* 7, 133190–133202.
- x IO (2013), Documentação ximu, <http://www.x-io.co.uk/downloads/x-IMU-User-Manual-v5.2.pdf>. Acessado em 11/11/2021.
- xSense (2021), Documentação xsens, <https://www.xsens.com/mti-1-imu>. Acessado em 11/11/2021.
- Zappi, P., Roggen, D., Farella, E., Troester, G. e Benini, L. (2012), Network-level power-performance trade-off in wearable activity recognition: A dynamic sensor selection approach, *ACM Transactions on Embedded Computing Systems* 11, 68:1–68:30.
- Zhang, J. (2020), Dynamic time warping: Explanation and code implementation. URL : <https://towardsdatascience.com/dynamic-time-warping-3933f25fcdd>
- Zhang, J., Wang, Q., Wang, Q. e Zheng, Z. (2023), Multimodal fusion framework based on statistical attention and contrastive attention for sign language recognition, *IEEE Transactions on Mobile Computing* pp. 1–13.

- Zhang, M. e Sawchuk, A. A. (2012), Usc-had: A daily activity dataset for ubiquitous activity recognition using wearable sensors, *in* ACM International Conference on Ubiquitous Computing (Ubicomp) Workshop on Situation, Activity and Goal Awareness (SAGAware), Pittsburgh, Pennsylvania, USA.
- Zhou, S.-y., Li, B., Chen, J. e Yuan, H. (2023), Kinematics parameter analysis of long jump based on human posture vision, *in* 2023 4th International Conference on Information Science, Parallel and Distributed Systems (ISPDS), pp. 349–354.