UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Bauru

Maicon Monttozo Batista

eMove: Análise Computacional de Movimentos Humanos com Apoio de Inteligência Artificial em Reabilitação Física e Neurofuncional

Bauru, São Paulo, Brasil

2026

Maicon Monttozo Batista

eMove: Análise Computacional de Movimentos Humanos com Apoio de Inteligência Artificial em Reabilitação Física e Neurofuncional

Dissertação de Mestrado elaborada junto ao Programa de Pós-Graduação em Ciência da Computação – Área de Concentração em Computação Aplicada, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Universidade Estadual Paulista "Júlio de Mesquita Filho"

Faculdade de Ciências - Câmpus de Bauru

Programa de Pós-Graduação em Ciência da Computação

Orientador: Prof. Dr. José Remo Ferreira Brega

Bauru, São Paulo, Brasil

2026

B333e

Batista, Maicon Monttozo
eMove : Análise Computacional de Movimentos Humanos com Apoio de Inteligência Artificial em Reabilitação Física e Neurofuncional / Maicon Monttozo Batista. -- Bauru, 2026
112 p. : il., tabs.

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências, Bauru
Orientador: José Remo Ferreira Brega

1. Inteligência Artificial. 2. Análise Computacional de Movimentos Humanos. 3. Reabilitação Física e Neurofuncional. 4. Classificação Supervisionada. 5. Visão Computacional. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

IMPACTO POTENCIAL DESTA PESQUISA

O impacto potencial desta pesquisa está relacionado ao desenvolvimento de uma solução computacional de apoio à análise, classificação e acompanhamento de movimentos humanos em contextos de reabilitação física e neurofuncional. Ao estruturar informações extraídas de vídeos, como pontos corporais, ângulos articulares, atributos cinemáticos e repetições de movimentos, o *eMove* pode contribuir para tornar o acompanhamento funcional mais objetivo, rastreável e comparável ao longo do tempo.

Do ponto de vista científico e técnico, o trabalho integra métodos de visão computacional, extração de pose, segmentação temporal, classificação supervisionada, agrupamento e curadoria especializada, oferecendo uma base computacional para estudos futuros em análise de movimentos humanos. No âmbito social e aplicado, a proposta busca apoiar profissionais da saúde na organização de dados de avaliação funcional, sem substituir a interpretação clínica, favorecendo a produção de relatórios e o acompanhamento longitudinal de pacientes em reabilitação.

Além disso, a solução contribui para a formação de uma base tecnológica nacional voltada à interface entre Ciência da Computação e Saúde, com potencial de expansão para novos protocolos, movimentos e bases de dados. Seus resultados podem subsidiar pesquisas futuras, aprimoramentos metodológicos e aplicações em ambientes clínicos, educacionais e de pesquisa, respeitando a necessidade de validação especializada e de atenção à privacidade dos dados.

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Bauru

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE MAICON MONTTOZO BATISTA, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO, DA FACULDADE DE CIÊNCIAS - CÂMPUS DE BAURU.

Aos 02 de setembro de 2026, às 14h30min, por meio de Videoconferência, realizou-se a defesa de DISSERTAÇÃO DE MESTRADO de MAICON MONTTOZO BATISTA, intitulada "eMove: Análise Computacional de Movimentos Humanos com Apoio de Inteligência Artificial em Reabilitação Física e Neurofuncional". A Comissão Examinadora foi constituída pelos seguintes membros: Professor Titular JOSÉ REMO FERREIRA BREGA (Orientador(a) - Participação Virtual) do(a) Diretoria / UNESP / Câmpus de Bauru - FC, Prof. Dr. ALEXANDRE CARDOSO (Participação Virtual) do(a) Faculdade de Engenharia Elétrica / Universidade Federal de Uberlândia, Prof. Dr. ROGÉRIO EDUARDO GARCIA (Participação Virtual) do(a) Departamento de Matemática e Computação / UNESP / Câmpus de Presidente Prudente - FCT, Após a exposição pelo mestrando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final:_ _ _ _ _ _ _ _ _ _ _ _ _ APROVADO _ _ _ . Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.

Assinado de forma digital por JOSE REMO FERREIRA BREGA:09610599826
Dados: 2026.09.02 16:26:31 -03'00'

Professor Titular JOSÉ REMO FERREIRA BREGA

Maicon Monttozo Batista

eMove: Análise Computacional de Movimentos Humanos com Apoio de Inteligência Artificial em Reabilitação Física e Neurofuncional

Dissertação de Mestrado elaborada junto ao Programa de Pós-Graduação em Ciência da Computação – Área de Concentração em Computação Aplicada, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Banca examinadora:

Prof. Dr. José Remo Ferreira Brega
UNESP – Câmpus de Bauru - FC
Orientador

Prof. Dr. Alexandre Cardoso
Universidade Federal de Uberlândia (UFU)

Prof. Dr. Rogério Eduardo Garcia
UNESP - Câmpus de Presidente Prudente - FCT

Bauru, São Paulo, Brasil
2026

À minha mãe Celina e minha esposa Mariana.

Agradecimentos

Primeiramente, agradeço a Deus por todas as bênçãos e oportunidades concedidas ao longo desta jornada.

Expresso minha profunda gratidão ao meu orientador, Prof. Dr. José Remo Ferreira Brega, pela paciência, dedicação e orientação incansável, que foram essenciais para a realização deste trabalho.

À minha mãe, Celina, que, mesmo não estando mais presente fisicamente, continua a ser minha maior inspiração e fonte de força. Sua memória me motiva a buscar sempre o melhor e a honrar seus ensinamentos.

À minha esposa, Mariana, pelo amor, apoio incondicional e compreensão durante os desafios enfrentados ao longo do mestrado. Sua presença ao meu lado foi fundamental para que eu pudesse superar cada etapa deste percurso.

Ao meu amigo Gabriel, por sua ajuda, incentivo constante e generosidade em compartilhar conhecimentos e experiências. Este trabalho é, em parte, uma continuidade do legado que ele iniciou, e sou profundamente grato por sua contribuição e amizade. Agradeço também ao André Zanchi, pela compreensão nos meus momentos de ausência, e por estar sempre disposto a me ajudar.

Ao professor Alexandre, cuja dedicação e experiência foram decisivas para que o software se tornasse utilizável e compatível com diferentes movimentos. Ao Luis Guilherme, pela participação ativa e pelas contribuições constantes a este trabalho.

"As oportunidades multiplicam-se à medida que são agarradas."

- Sun Tzu.

Resumo

A análise computacional de movimentos humanos com apoio de Inteligência Artificial (IA) tem ganhado destaque em contextos de reabilitação física e neurofuncional, permitindo transformar execuções motoras em informações quantitativas que podem apoiar a avaliação da evolução funcional. Entretanto, a aplicação prática desses métodos ainda enfrenta desafios relacionados à variabilidade dos movimentos, às limitações dos conjuntos de dados, à necessidade de curadoria especializada e à demanda por maior transparência na interpretação dos resultados. Nesse contexto, este trabalho investiga métodos computacionais para análise, classificação e acompanhamento de movimentos humanos em reabilitação física e neurofuncional, apresentando, implementando e avaliando uma solução computacional denominada *eMove*, desenvolvida para apoiar profissionais da saúde (especialistas em Cinesiologia) na avaliação da evolução funcional. Como base metodológica, foi conduzida uma Revisão Sistemática da Literatura (RSL) que mapeou técnicas recorrentes, modalidades de captura, características dos conjuntos de dados, tecnologias empregadas e abordagens de modelagem, a partir da análise de 23 estudos selecionados. Com base nas evidências identificadas, foram definidas as decisões de projeto e desenvolvido um pipeline de análise integrado ao *eMove*, contemplando aquisição e importação de vídeos, extração de pose corporal, cálculo de ângulos articulares, segmentação automática de sessões em repetições, extração de atributos cinemáticos, agrupamento por similaridade, classificação supervisionada, curadoria especializada e geração de relatórios para acompanhamento longitudinal. Os resultados computacionais demonstram a consolidação do pipeline proposto, evidenciando a viabilidade da segmentação das sessões, da representação tabular das repetições, da organização automática dos movimentos por agrupamento e da utilização de modelos supervisionados como apoio à classificação. A solução também incorpora mecanismos voltados à interpretabilidade, utilizando atributos compreensíveis aos profissionais da saúde e separando classificações automáticas da validação especializada. Embora a validação clínica em larga escala ainda dependa da ampliação da base de dados, da inclusão de diferentes movimentos e da avaliação sistemática por especialistas, os resultados obtidos indicam que a arquitetura, os métodos e o pipeline desenvolvidos constituem uma base consistente para futuras aplicações em ambientes clínicos e de pesquisa.

Palavras-chave: Inteligência Artificial; Análise Computacional de Movimentos Humanos; Reabilitação Física e Neurofuncional; Classificação Supervisionada; Visão Computacional.

Abstract

Computational analysis of human movement supported by Artificial Intelligence (AI) has gained increasing attention in physical and neurofunctional rehabilitation by enabling motor executions to be transformed into quantitative information that supports the assessment of functional progress. Nevertheless, the practical application of these methods still faces challenges related to movement variability, limited datasets, the need for expert curation, and the demand for greater transparency in the interpretation of computational results. In this context, this work investigates computational methods for the analysis, classification, and monitoring of human movement in rehabilitation scenarios, presenting, implementing, and evaluating a computational solution named *eMove*, developed to support healthcare professionals with expertise in kinesiology during the assessment of functional progress. As its methodological foundation, this work conducts a Systematic Literature Review (SLR) to identify recurring techniques, motion acquisition modalities, dataset characteristics, technologies, and modeling approaches based on the analysis of 23 selected studies. Based on the evidence gathered, an integrated analysis pipeline was designed and implemented within *eMove*, comprising video acquisition and import, human pose estimation, joint angle computation, automatic segmentation of exercise sessions into individual repetitions, kinematic attribute extraction, similarity-based clustering, supervised classification, expert curation, and longitudinal assessment reports. Computational results demonstrate the feasibility of the proposed pipeline, highlighting the effectiveness of automatic repetition segmentation, the tabular representation of movement executions, automatic clustering, and supervised learning models for supporting movement classification. The proposed solution also incorporates mechanisms to improve interpretability by employing clinically understandable attributes and clearly separating automatic classifications from expert validation. Although large-scale clinical validation still depends on larger datasets, a wider variety of movements, and systematic evaluation by healthcare specialists, the results indicate that the proposed computational solution provides a consistent foundation for future clinical and research applications.

Keywords: Artificial Intelligence; Computational Human Movement Analysis; Physical and Neurofunctional Rehabilitation; Supervised Classification; Computer Vision.

Lista de ilustrações

Figura 1 – Gráfico de artigos por ano aprovados 45
Figura 2 – Gráfico de artigos por fonte e ano 45
Figura 3 – Autoria do conjunto de dados 46
Figura 4 – Quantidade de artigos por tipo de captura 48
Figura 5 – Quantidade de artigos por natureza das atividades 49
Figura 6 – Visão funcional do eMove, destacando os atores e as principais funcionalidades do sistema. 64
Figura 7 – Arquitetura técnica do eMove organizada em camadas funcionais 65
Figura 8 – Modelo de informação utilizado pelo eMove para organização do acompanhamento longitudinal 66
Figura 9 – Conjunto de 33 *landmarks* corporais detectados pela MediaPipe Pose Landmarker. 67
Figura 10 – Exemplo de curva de ângulo com limites de histerese, ilustrando *preroll*, região útil e *postroll*. 69
Figura 11 – Interface de cadastro de movimentos no eMove 76
Figura 12 – Interface de análise de sessões no eMove 77
Figura 13 – Gráfico de uma sessão segmentada em repetições 78
Figura 14 – Interface de classificação das repetições da sessão 79
Figura 15 – Interface de treinamento do modelo de movimento 81
Figura 16 – Fluxo de classificação supervisionada com curadoria especializada no eMove 82
Figura 17 – Relatório exportado com dados anonimizados 83
Figura 18 – Fluxo consolidado de processamento e análise adotado no eMove 86
Figura 19 – Visualização dos agrupamentos identificados pelo HDBSCAN utilizando projeção UMAP 91
Figura 20 – Interface de avaliação do modelo supervisionado no eMove 94
Figura 21 – Distribuição das classes utilizadas na avaliação supervisionada 95
Figura 22 – Matriz de confusão agregada da validação supervisionada 96
Figura 23 – Importância média dos atributos calculada pelo Random Forest 97

Lista de tabelas

Tabela 1 – Estratégia final de busca utilizada na revisão sistemática 37
Tabela 2 – Quantidade de documentos retornados por base científica 37
Tabela 3 – Resumo do processo de seleção dos estudos 39
Tabela 4 – Síntese metodológica da revisão sistemática 41
Tabela 5 – Artigos selecionados na revisão sistemática 43
Tabela 6 – Tecnologias identificadas nos estudos selecionados 50
Tabela 7 – Abordagens identificadas nos estudos selecionados 51
Tabela 8 – Resultados de desempenho observados nos estudos da RSL quando reportados 53
Tabela 9 – Síntese detalhada dos estudos selecionados conforme as perguntas da revisão 56
Tabela 10 – Síntese comparativa dos principais achados da revisão 58
Tabela 11 – Relação entre evidências da RSL, requisitos e decisões de arquitetura do eMove 63
Tabela 12 – Exemplo de atributos extraídos das repetições de uma sessão 87
Tabela 13 – Resumo da base utilizada na avaliação dos agrupamentos 90
Tabela 14 – Hiperparâmetros do HDBSCAN utilizados na avaliação dos agrupamentos . 90
Tabela 15 – Caracterização dos grupos identificados pelo HDBSCAN 91
Tabela 16 – Características médias dos grupos identificados 92
Tabela 17 – Métricas obtidas na avaliação supervisionada com Random Forest 94
Tabela 18 – Hiperparâmetros do RandomForestClassifier utilizados na avaliação supervisionada 95

Lista de Abreviaturas e Siglas

ACM Associação para Maquinaria da Computação (*Association for Computing Machinery*)

AI Artificial Intelligence

AVC Acidente Vascular Cerebral

CAPES Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

CNN Rede Neural Convolucional (*Convolutional Neural Network*)

DTW Distorção Dinâmica do Tempo (*Dynamic Time Warping*)

eMove eMove (Software de análise de movimentos humanos para reabilitação física e neurofuncional)

HDBSCAN Agrupamento Hierárquico Baseado em Densidade para Aplicações com Ruído (*Hierarchical Density-Based Spatial Clustering of Applications with Noise*)

IA Inteligência Artificial

IEEE Instituto de Engenheiros Elétricos e Eletrônicos (*Institute of Electrical and Electronic Engineers*)

IMU Unidade de Medição Inercial (*Inertial Measurement Unit*)

IoT Internet das coisas (*Internet of Things*)

k-NN k-Vizinhos Mais Próximos (*k-Nearest Neighbors*)

LGPD Lei Geral de Proteção de Dados

OpenCV Open Source Computer Vision Library

RF Florestas Aleatórias (*Random Forests*)

RNN Rede Neural Recorrente (*Recurrent Neural Network*)

RSL Revisão Sistemática da Literatura

sEMG Eletromiografia de Superfície (*Surface Electromyography*)

SLR Systematic Literature Review

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

UNESP Universidade Estadual Paulista “Júlio de Mesquita Filho”

ViTs Transformadores de Visão (*Vision Transformers*)

VPN Rede Virtual Privada (*Virtual Private Network*)

XAI Inteligência Artificial Explicável (*Explainable Artificial Intelligence*)

Sumário

1 INTRODUÇÃO 18
1.1 Contextualização e motivação 18
1.2 Objetivos 19
1.2.1 Objetivo geral 19
1.2.2 Objetivos específicos 20
1.3 Organização do trabalho 20

2 FUNDAMENTAÇÃO TEÓRICA 22
2.1 Inteligência Artificial e Aprendizado de Máquina na Saúde 22
2.2 Técnicas de Análise e Classificação de Movimentos 23
2.3 Análise Computacional de Movimentos Humanos 25
2.4 Reabilitação Física e Neurofuncional 27
2.5 Captura de Movimento por Vídeo e Sensores 29
2.6 Extração de Pose e Representação por Landmarks 30
2.7 Séries Temporais e Alinhamento Temporal 31
2.8 Agrupamento, Classificação e Curadoria Especializada 32
2.9 Interpretabilidade e Explicabilidade em Sistemas de Apoio à Saúde 33
2.10 Considerações Finais 34

3 REVISÃO SISTEMÁTICA DA LITERATURA 35
3.1 Planejamento da Revisão 35
3.2 Questão de Pesquisa 35
3.3 Bases de Dados Consultadas 36
3.4 Estratégia de Busca 36
3.5 Critérios de Inclusão e Exclusão 37
3.6 Processo de Seleção dos Estudos 38
3.7 Dados Extraídos dos Estudos 39
3.8 Síntese e Organização dos Dados 40
3.9 Considerações Finais 41

4 RESULTADOS DA REVISÃO SISTEMÁTICA 42
4.1 Caracterização Geral dos Estudos Selecionados 42
4.2 Origem dos Conjuntos de Dados e Estratégias de Coleta 45
4.3 Modalidades de Captura e Representação dos Movimentos 47
4.4 Natureza das Atividades e Contextos de Aplicação 48
4.5 Tecnologias, Ferramentas e Técnicas Computacionais 49

4.6 Abordagens de Modelagem, Classificação e Agrupamento 50
4.7 Desempenho dos Modelos 51
4.8 Aplicações Práticas Identificadas 53
4.9 Síntese Comparativa dos Trabalhos Selecionados 54
4.10 Lacunas Identificadas na Literatura 58
4.11 Implicações dos Resultados da Revisão para o eMove 59
4.12 Considerações Finais 60

5 ARQUITETURA DA SOLUÇÃO E PIPELINE DE ANÁLISE 61
5.1 Visão Geral da Solução Proposta 61
5.2 Relação entre a Revisão Sistemática e as Decisões de Projeto . . . 62
5.3 Arquitetura Geral e Modelo de Informação 63
5.4 Aquisição e Representação dos Dados de Movimento 66
5.5 Cálculo Cinemático e Pré-processamento das Séries Temporais . . 67
5.6 Segmentação, Atributos e Organização por Similaridade 68
5.7 Classificação, Agrupamento e Apoio à Curadoria 70
5.8 Saídas Analíticas, Relatórios e Governança dos Dados 70
5.9 Considerações Finais 71

6 IMPLEMENTAÇÃO E RECURSOS DESENVOLVIDOS NO EMOVE 73
6.1 Visão Geral da Implementação 73
6.2 Modelo de Dados e Organização do Acompanhamento 73
6.3 Controle de Acesso, Multiempresa e Compartilhamento de Pacientes 74
6.4 Aquisição, Importação e Processamento dos Dados de Movimento 75
6.5 Segmentação Configurável e Atributos por Repetição 76
6.6 Classificação, Curadoria e Templates de Referência 78
6.7 Agrupamento Automático e Classificação Supervisionada 80
6.8 Relatórios, Privacidade e Adequação à LGPD 82
6.9 Atualização e Manutenção da Aplicação 83
6.10 Considerações Finais 84

7 RESULTADOS COMPUTACIONAIS E DISCUSSÃO 85
7.1 Consolidação do Pipeline de Análise 85
7.2 Segmentação, Atributos e Representação das Repetições 86
7.3 Classificação das Repetições e Curadoria Especializada 87
7.4 Agrupamento Automático e Interpretação dos Padrões 88
7.5 Classificação Supervisionada com Atributos Tabulares 92
7.6 Relatórios, Interpretabilidade e Acompanhamento Longitudinal . . . 98
7.7 Limitações Atuais 99
7.8 Considerações Finais 100

8 CONSIDERAÇÕES FINAIS 102
8.1 Síntese do Trabalho 102
8.2 Atendimento aos Objetivos 103
8.3 Principais Contribuições 103
8.4 Limitações 105
8.5 Trabalhos Futuros 105

REFERÊNCIAS 107

1 Introdução

1.1 Contextualização e motivação

A análise computacional de movimentos humanos tem sido explorada em contextos de reabilitação física e neurofuncional, pois permite representar, comparar e avaliar execuções motoras a partir de dados visuais e cinemáticos (DEBNATH et al., 2022). Na área da saúde, esse tipo de análise pode contribuir para o acompanhamento da evolução funcional dos pacientes, principalmente quando os movimentos são transformados em informações mensuráveis e comparáveis ao longo do tempo.

Tradicionalmente, parte da avaliação da evolução funcional depende da observação clínica realizada por profissionais da saúde. Essa avaliação é essencial, pois considera aspectos individuais do paciente e a interpretação especializada do movimento. No entanto, ela pode ser complementada por métodos computacionais capazes de organizar a execução motora em dados objetivos, como séries temporais, ângulos articulares, métricas de amplitude, duração e padrões de compensação. Dessa forma, diferentes execuções de um mesmo movimento podem ser analisadas de maneira mais estruturada, favorecendo o acompanhamento longitudinal e a identificação de variações entre sessões.

A medição manual de ângulos articulares pode ser realizada por meio da goniometria, utilizando instrumentos como o goniômetro, empregado para quantificar limitações articulares e comparar avaliações iniciais com reavaliações (MARQUES, 2003). Embora esse tipo de medição seja importante na prática avaliativa, trata-se de um procedimento manual e geralmente pontual. Por isso, pode ser complementado por soluções digitais capazes de registrar a variação angular ao longo do tempo. Nesse sentido, a proposta do eMove (Software de análise de movimentos humanos para reabilitação física e neurofuncional) (eMove) busca apoiar a quantificação padronizada dos dados cinemáticos por vídeo, tornando o registro dos ângulos e das repetições mais rastreável durante o acompanhamento.

Para viabilizar esse tipo de análise, a captura de movimentos pode ser realizada por diferentes tecnologias, como câmeras, sensores vestíveis, unidades de medição inercial e sinais de eletromiografia de superfície. Unidade de Medição Inercial (*Inertial Measurement Unit*) (IMU) e Eletromiografia de Superfície (*Surface Electromyography*) (sEMG), por exemplo, são utilizadas em estudos biomecânicos e clínicos para registrar informações associadas ao movimento muscular e articular (STUART; MARTYN, 2018). Já em aplicações de telereabilitação, a estimação de pose por visão computacional tem sido explorada para acompanhar exercícios a partir de câmeras convencionais (ROSIQUE; LOSILLA; NAVARRO, 2021). Essa abordagem sem marcadores permite estimar pontos corporais em imagens ou vídeos, diminuindo a necessidade de sensores

físicos acoplados ao corpo (HELLSTEN et al., 2021).

A partir dos dados capturados, diferentes técnicas computacionais podem ser utilizadas para analisar a execução dos movimentos. Nesse cenário, métodos de aprendizado profundo e estimação de pose têm sido aplicados para avaliar movimentos corporais e apoiar a interpretação da execução motora (THARATIPYAKUL; SRIKAEWSIEW; PONGNUMKUL, 2024). Métodos como Rede Neural Convolucional (*Convolutional Neural Network*) (CNN) podem ser aplicados à análise de imagens e vídeos, enquanto Rede Neural Recorrente (*Recurrent Neural Network*) (RNN) são adequadas para dados sequenciais e séries temporais (GOODFELLOW; BENGIO; COURVILLE, 2016). Técnicas clássicas de aprendizado de máquina, como Máquina de Vetores de Suporte (*Support Vector Machine*) (SVM) e Florestas Aleatórias (*Random Forests*) (RF), também continuam relevantes, especialmente em situações com conjuntos de dados menores ou com atributos previamente extraídos (BISHOP, 2006).

Apesar desses avanços, a aplicação prática de métodos computacionais em reabilitação ainda apresenta desafios. Entre eles, destacam-se a variabilidade entre pacientes, a necessidade de adaptação a diferentes movimentos, a limitação de bases de dados clínicas, a dependência de rotulagem especializada e a necessidade de apresentar resultados compreensíveis ao profissional da saúde (AGUILAR-ORTEGA et al., 2023). Além disso, por se tratar de aplicações que podem envolver dados sensíveis, aspectos relacionados à privacidade, controle de acesso, rastreabilidade e proteção das informações precisam ser considerados desde a concepção da solução (YADAV et al., 2023).

Diante desse contexto, este trabalho apresenta o eMove, uma solução computacional voltada à análise de movimentos humanos em reabilitação física e neurofuncional. A proposta integra captura e importação de vídeos, extração de pose corporal, cálculo de ângulos articulares, segmentação de sessões em repetições, extração de atributos, organização de repetições por similaridade, apoio à classificação e geração de relatórios de acompanhamento. O pós-Acidente Vascular Cerebral (AVC) é considerado como um dos possíveis contextos de aplicação, sem restringir o escopo da solução apenas a esse cenário.

1.2 Objetivos

1.2.1 Objetivo geral

O objetivo geral do trabalho apresentado é propor e implementar uma solução computacional para apoiar a análise, a classificação e o acompanhamento de movimentos humanos em contextos de reabilitação física e neurofuncional, utilizando técnicas de análise de movimento, segmentação em repetições, extração de atributos e métodos de inteligência artificial como apoio à interpretação dos dados.

1.2.2 Objetivos específicos

1. Conduzir uma revisão sistemática da literatura para mapear técnicas computacionais e métodos de Inteligência Artificial (IA) aplicados à análise, classificação e acompanhamento de movimentos humanos em contextos de saúde e reabilitação;

2. Especificar a arquitetura do eMove com base nas lacunas identificadas na literatura e nas necessidades de análise de movimentos em reabilitação física e neurofuncional;

3. Implementar um pipeline para aquisição e importação de vídeos, extração de pose corporal, cálculo de ângulos articulares, segmentação de sessões em repetições e extração de atributos por repetição;

4. Desenvolver mecanismos de apoio à classificação e interpretação das repetições, incluindo organização por similaridade, agrupamento automático, classificação supervisionada e curadoria especializada.

1.3 Organização do trabalho

Este trabalho está organizado em oito capítulos. Após esta introdução, o Capítulo 2 apresenta a fundamentação teórica relacionada à inteligência artificial, aprendizado de máquina, análise computacional de movimentos humanos, reabilitação física e neurofuncional, captura de movimento, extração de pose, séries temporais, agrupamento, classificação e interpretabilidade em sistemas de apoio à saúde.

O Capítulo 3 descreve a metodologia da revisão sistemática da literatura, incluindo o planejamento da revisão, a questão de pesquisa, as bases consultadas, a estratégia final de busca, os critérios de inclusão e exclusão, o processo de seleção dos estudos e os dados extraídos para análise.

O Capítulo 4 apresenta os resultados da revisão sistemática, discutindo a caracterização dos estudos selecionados, a origem dos conjuntos de dados, as modalidades de captura, as tecnologias utilizadas, as abordagens de modelagem e as lacunas identificadas. Esse capítulo também relaciona os achados da literatura às decisões adotadas no desenvolvimento do eMove.

O Capítulo 5 descreve a arquitetura da solução e o pipeline de análise proposto, abordando o modelo de informação utilizado, o fluxo de aquisição e processamento dos dados, a extração de pose, o cálculo de ângulos, a segmentação em repetições, a extração de atributos, a organização por similaridade, a geração de saídas analíticas e os aspectos de governança, privacidade e rastreabilidade.

O Capítulo 6 apresenta a implementação e os recursos desenvolvidos no eMove, incluindo o modelo de dados, controle de acesso, organização multiempresa, compartilhamento de pacientes, aquisição por câmera, importação de vídeo, segmentação configurável por sessão,

classificação por faixas, movimentos de referência, agrupamento automático, classificação supervisionada, relatórios de acompanhamento da evolução funcional e mecanismos relacionados à privacidade e manutenção da aplicação.

O Capítulo 7 discute os resultados computacionais obtidos, considerando a consolidação do pipeline de análise, a segmentação das sessões em repetições, os atributos extraídos, a classificação das repetições, o agrupamento automático, a classificação supervisionada com atributos tabulares, os relatórios gerados, a interpretabilidade dos resultados e as limitações atuais da solução.

Por fim, o Capítulo 8 apresenta as considerações finais, retomando a síntese do trabalho, o atendimento aos objetivos, as principais contribuições, as limitações identificadas e os trabalhos futuros.

2 Fundamentação Teórica

Este capítulo apresenta os principais conceitos que fundamentam o desenvolvimento deste trabalho, considerando a relação entre IA, aprendizado de máquina, análise computacional de movimentos humanos e reabilitação física e neurofuncional. A discussão também aborda técnicas de captura de movimento, extração de pose, representação por *landmarks*, séries temporais, alinhamento temporal, agrupamento, classificação, curadoria especializada e interpretabilidade em sistemas de apoio à saúde.

A ideia é estabelecer uma base conceitual para os capítulos seguintes, especialmente para a Revisão Sistemática da Literatura (RSL) e para a apresentação da arquitetura computacional proposta neste trabalho. Além de contextualizar as técnicas utilizadas, o capítulo explicita como o movimento registrado em vídeo pode ser transformado em dados, medidas, séries temporais e atributos interpretáveis, formando a base para o pipeline desenvolvido no eMove.

2.1 Inteligência Artificial e Aprendizado de Máquina na Saúde

A proposta de desenvolver máquinas inteligentes, capazes de simular alguns aspectos do raciocínio humano, envolve contribuições de áreas como ciência da computação, linguística, psicologia e ciência cognitiva. De modo geral, a IA busca desenvolver métodos capazes de reconhecer padrões, aprender a partir de dados e apoiar processos de tomada de decisão em diferentes domínios.

John McCarthy introduziu o termo Inteligência Artificial em uma conferência organizada no Dartmouth College, nos Estados Unidos, no ano de 1956 (MCCARTHY, 2006). No entanto, a discussão sobre máquinas inteligentes já existia antes desse período, sendo que Alan Turing, em 1950, apresentou reflexões importantes em “Computing Machinery and Intelligence”, trabalho amplamente considerado pioneiro na computação moderna (TURING, 1950).

A IA tem sido empregada em diferentes áreas, como medicina, diagnóstico, indústria, manufatura e logística. Na saúde, essas técnicas podem apoiar tarefas como reconhecimento de padrões, previsão de resultados, organização de dados e auxílio à tomada de decisão. Na reabilitação, por exemplo, métodos computacionais podem contribuir para reconhecer e classificar movimentos, fornecendo informações de apoio para pacientes e profissionais da saúde (ZHANG et al., 2023b).

Tarefas como reconhecimento de padrões e previsão de resultados tornaram-se adequadas para sistemas baseados em IA. Com os avanços em aprendizado de máquina e aprendizado profundo, essas técnicas passaram a ser aplicadas em diferentes contextos da saúde, inclusive na análise de movimentos humanos e no acompanhamento de processos de reabilitação.

Essas tecnologias, porém, dependem da disponibilidade e da qualidade dos dados utilizados no treinamento, validação e teste dos modelos. Em aplicações preditivas ou baseadas em aprendizado profundo, bases maiores, bem rotuladas e representativas tendem a favorecer maior capacidade de generalização; contudo, em contextos clínicos e de reabilitação, a coleta de dados pode ser limitada pela variabilidade dos pacientes, dos protocolos e das condições de execução. Por isso, torna-se importante combinar estratégias de extração de atributos, curadoria especializada e avaliação criteriosa dos resultados, em vez de assumir que o volume de dados, isoladamente, seja suficiente para garantir bons modelos (MU; DAI; MA, 2021; ZENG, 2022). Nesse cenário, a IA tem sido utilizada como recurso de apoio à assistência e à quantificação da melhoria funcional durante o processo de recuperação (SEO et al., 2021; ZHANG et al., 2023b).

A reabilitação associada à IA constitui um campo de pesquisa em expansão, principalmente quando se considera a possibilidade de apoiar intervenções terapêuticas voltadas a pessoas com dificuldades motoras. A classificação de movimento com o apoio de algoritmos de aprendizado profundo, como CNN e RNN, é frequentemente utilizada para reconhecer padrões de execução motora. Esse tipo de abordagem é relevante em contextos de reabilitação física e neurofuncional, incluindo casos pós-AVC, pois permite uma análise mais próxima da execução dos movimentos e pode auxiliar ajustes nos planos terapêuticos conforme as necessidades do paciente (SEO et al., 2021; TSAI; HUANG, 2022).

De forma complementar, modelos de reconhecimento e monitoramento de movimento também têm sido investigados em diferentes aplicações na área da saúde, como monitoramento remoto de pacientes, prevenção de lesões, análise de desempenho e incorporação de abordagens explicáveis. Esses usos indicam que a IA vem se consolidando como uma área relevante em contextos clínicos e computacionais, especialmente quando associada à análise padronizada de dados relacionados ao movimento humano (TOPOL, 2019).

A partir desse cenário, é necessário compreender quais técnicas computacionais têm sido utilizadas para analisar e classificar movimentos humanos, especialmente quando esses movimentos são registrados por vídeos, sensores ou representações temporais.

2.2 Técnicas de Análise e Classificação de Movimentos

Vários métodos de classificação de movimento foram investigados nos últimos anos para melhorar o reconhecimento e a análise de atividades humanas. CNN, RNN, Transformadores de Visão (*Vision Transformers*) (ViTs), juntamente com outros métodos, foram avaliados em diferentes estudos e apresentaram resultados relevantes conforme o tipo de dado utilizado e o objetivo da análise.

As CNNs são conhecidas por apresentarem bom desempenho no reconhecimento de padrões em imagens e vídeos. Na reabilitação, elas podem ser utilizadas para analisar sequências de imagens obtidas durante a execução de exercícios terapêuticos, auxiliando na classificação de

diferentes tipos de movimentos (RAO, 2022).

As RNNs, por sua vez, são aplicáveis a dados sequenciais, como séries temporais associadas à execução de movimentos. Em algumas abordagens, elas também são combinadas com CNNs para complementar a análise de padrões espaciais e temporais (SEO et al., 2021).

Os ViTs, ramo mais recente do aprendizado profundo, utilizam mecanismos de atenção originalmente empregados em processamento de linguagem natural para o reconhecimento de padrões em imagens. Esses modelos dividem imagens em pequenas unidades, chamadas de *patches*, e interpretam cada bloco como uma sequência de entrada.

Cada bloco pode ser modelado como parte de uma sequência, permitindo capturar dependências globais entre regiões da imagem (ZHENG; JING; XU, 2019; GEMAN et al., 2019). Essa característica pode ser útil em aplicações que exigem compreensão mais ampla da cena ou do corpo durante a execução de movimentos.

Redes de aprendizado residual também podem contribuir para aumentar a eficiência de arquiteturas profundas, reduzindo problemas como o desaparecimento do gradiente e permitindo o treinamento de redes com maior número de camadas. Essa integração de técnicas pode ser útil em aplicações que necessitam de maior precisão, como reabilitação motora guiada por sensores ou vídeos (SU; SU, 2020; RAO, 2022).

Diversas técnicas são utilizadas para reduzir o sobreajuste, que é um problema típico em aprendizado de máquina no qual os modelos se ajustam excessivamente aos dados de treinamento e perdem capacidade de generalização. A regularização provoca penalidades aos parâmetros do modelo para promover soluções mais simples, enquanto métodos como *dropout* desativam aleatoriamente uma fração dos neurônios durante o treinamento, tornando modelos mais robustos (GOODFELLOW; BENGIO; COURVILLE, 2016).

As técnicas de pré-processamento também são importantes para melhorar o desempenho dos modelos de IA. A normalização, por exemplo, modifica as escalas das variáveis para facilitar o aprendizado, enquanto a extração de características busca identificar os padrões mais importantes para a tarefa, reduzindo ruído e redundância nos dados (GOODFELLOW; BENGIO; COURVILLE, 2016).

Além das abordagens baseadas em imagens ou sequências completas, outra possibilidade é representar cada execução de movimento por um conjunto de atributos extraídos, como amplitude, duração, variação angular e medidas de similaridade. Essa representação tabular permite o uso de algoritmos supervisionados tradicionais, como árvores de decisão, florestas aleatórias e métodos baseados em vizinhança (BISHOP, 2006; FRANGOUDES et al., 2022). Em movimentos do membro superior, por exemplo, medidas relacionadas à execução principal e às compensações do tronco e do ombro podem fornecer informações relevantes para uma análise quantitativa inicial da execução motora (LIU et al., 2025).

Algoritmos baseados em grafos também ganharam destaque, especialmente para repre-

sentar ações humanas em situações de reabilitação. Esses métodos modelam movimentos como estruturas gráficas, considerando relações espaciais e temporais entre diferentes partes do corpo. Dessa forma, conseguem representar dependências complexas entre pontos corporais e padrões de movimento (TSAI; HUANG, 2022).

Essas abordagens oferecem possibilidades relevantes para a aplicação de aprendizado de máquina em tarefas de análise e classificação de movimento. Quando combinadas com técnicas adequadas de captura, pré-processamento e extração de atributos, podem contribuir para modelos mais úteis em ambientes relacionados à reabilitação motora.

Essas técnicas dependem diretamente da forma como o movimento humano é representado computacionalmente. Antes de discutir aplicações específicas em reabilitação, é importante compreender como uma execução motora pode ser transformada em dados passíveis de análise.

2.3 Análise Computacional de Movimentos Humanos

A análise computacional de movimentos humanos consiste na transformação de execuções motoras em dados estruturados. A partir dessa transformação, características como trajetória, amplitude, duração, variação angular e padrões de compensação podem ser avaliadas de forma quantitativa. Essa área reúne conceitos de visão computacional, processamento de sinais, aprendizado de máquina e análise biomecânica, mas com um objetivo prático: tornar o movimento observável também por meio de dados.

Esse processo não ocorre em uma única etapa. Inicialmente, a execução do movimento precisa ser capturada por vídeo, sensores ou outro dispositivo capaz de registrar sua evolução ao longo do tempo. Em seguida, os dados brutos passam por uma etapa de representação, na qual imagens, sinais ou coordenadas são convertidos em estruturas computacionais. No caso de abordagens baseadas em vídeo, essa representação pode ocorrer por meio da estimação de pose, que identifica pontos corporais em cada quadro e permite acompanhar a posição relativa de segmentos como ombro, cotovelo, punho, quadril, joelho e tornozelo.

A partir dessa representação, medidas cinemáticas podem ser calculadas. Ângulos articulares, por exemplo, podem ser obtidos pela relação geométrica entre três pontos corporais: um ponto central, correspondente à articulação analisada, e dois pontos adjacentes, que definem os segmentos envolvidos no movimento. Ao repetir esse cálculo quadro a quadro, a execução deixa de ser apenas uma imagem em movimento e passa a ser descrita por uma série temporal de ângulos. Essa série permite observar variações de amplitude, velocidade relativa, duração da execução, estabilidade do gesto e possíveis compensações corporais.

Depois da extração dessas séries temporais, torna-se necessário preparar os dados para análise. Essa preparação pode incluir suavização para reduzir oscilações do rastreamento, correção de orientação da curva, recorte temporal da região útil do movimento e segmentação da

sessão em repetições. A segmentação é particularmente importante em reabilitação, pois uma mesma sessão pode conter várias execuções do mesmo protocolo, com diferenças relevantes entre elas. Desse modo, cada repetição pode ser analisada individualmente e comparada com outras repetições da mesma sessão, de sessões anteriores ou de uma referência definida pelo profissional.

Por fim, os dados segmentados podem ser transformados em atributos. Esses atributos sintetizam informações importantes da execução, como amplitude máxima, amplitude mínima, variação angular, duração, compensação e distância em relação a uma referência temporal. A partir deles, podem ser aplicadas técnicas de agrupamento, classificação e visualização, sempre considerando que a interpretação final deve permanecer vinculada ao contexto clínico e à avaliação especializada.

Os modelos de reconhecimento e monitoramento de movimento têm aplicações significativas na área da saúde, especialmente no contexto da medição clínica em reabilitação (LAM; TANG; FONG, 2023). Nesse sentido, utilizar a visão computacional para transformar sessões em dados auxilia os profissionais da saúde (especialistas em Cinesiologia) a medir a execução dos movimentos de forma coerente e quantitativa, permitindo acompanhar mudanças no desempenho ao longo do tempo (STENUM et al., 2024).

A mensuração de ângulos articulares também pode ser realizada de forma manual por instrumentos como o goniômetro, bastante utilizado em avaliações do movimento humano. No entanto, por se tratar de uma medição manual e geralmente pontual, esse tipo de avaliação pode ser complementado por abordagens digitais capazes de registrar a variação angular durante a execução do movimento (MARQUES, 2003).

Na reabilitação física e neurofuncional, a precisão e a individualização desempenham papéis fundamentais. Cada paciente apresenta desafios diferentes e, nesse cenário, torna-se importante analisar não apenas as sessões de forma bruta, mas também os dados cinemáticos extraídos da execução dos movimentos. Dentro de cada sessão, existem repetições de um determinado movimento articular, que podem apresentar variações (WAGH et al., 2025).

Por exemplo, um paciente pode iniciar uma sessão com uma execução próxima do ideal e, com o tempo, apresentar queda na amplitude do movimento ou aumento na compensação. Ao analisar apenas a sessão como um todo, o profissional pode interpretar que houve melhoria geral, embora algumas repetições indiquem uma resposta funcional menos uniforme (LIU et al., 2025).

A segmentação da sessão em repetições se torna uma estratégia relevante, permitindo que cada execução realizada pelo paciente seja analisada de forma individualizada. Com essa segmentação, é possível estabelecer um movimento de referência para comparar uma repetição com outra, dentro da mesma sessão ou de outra sessão realizada pelo paciente, tornando a comparação mais realista para a avaliação da evolução funcional (ULLAH et al., 2025).

Com isso, a sessão deixa de ser analisada apenas como um bloco único e passa a ser

interpretada em nível de repetição. Essa mudança é importante porque medidas gerais da sessão podem ocultar repetições com redução de amplitude, presença de compensações ou diferenças na qualidade da execução (ULLAH et al., 2025).

Em uma sessão com dez repetições, por exemplo, o resultado médio pode indicar estabilidade, embora algumas execuções específicas apresentem redução de amplitude, aumento da compensação ou diferenças na trajetória do movimento. A análise individual das repetições permite observar essas variações e produzir informações mais detalhadas sobre a consistência, a amplitude e a qualidade da execução motora (ULLAH et al., 2025).

2.4 Reabilitação Física e Neurofuncional

Na reabilitação motora, a precisão e a individualização desempenham papéis fundamentais. Cada paciente apresenta desafios diferentes, e a IA pode identificar padrões de movimento que precisam de maior atenção (HE et al., 2021). Além disso, sensores vestíveis, vídeos ou tecnologias embarcadas baseadas em dispositivos Internet das coisas (*Internet of Things*) (IoT) podem fornecer dados para modelos computacionais, permitindo análises que apoiam ajustes nos exercícios e o acompanhamento da recuperação.

No contexto da fisioterapia e da reabilitação, os movimentos analisados costumam estar associados a protocolos de avaliação ou de intervenção. Um protocolo define a tarefa motora a ser executada, os segmentos corporais envolvidos, a posição inicial, a orientação do paciente, o plano de movimento, a quantidade de repetições esperada e os critérios observados pelo profissional. Nesta dissertação, o termo movimento é utilizado para manter a nomenclatura adotada no sistema eMove; contudo, esse movimento corresponde, do ponto de vista aplicado, a um protocolo configurável de análise.

Esses avanços aumentam a capacidade de estudar movimentos complexos e podem contribuir para a eficiência terapêutica quando utilizados como apoio ao profissional da saúde (SU; SU, 2020; GEMAN et al., 2019; RAO, 2022). No entanto, é importante considerar que os sistemas computacionais não substituem a avaliação especializada. Eles oferecem indicadores, mas a interpretação continua dependendo do profissional e do contexto do paciente.

Sensores vestíveis, como dispositivos sEMG e acelerômetros, ajudam na análise dos movimentos dos pacientes durante exercícios terapêuticos. Profissionais da saúde podem utilizar essas informações para ajustar exercícios e acompanhar a progressão dos pacientes, inclusive com o apoio de modelos baseados em aprendizado profundo, como CNN, para detectar padrões inadequados ou movimentos incorretos (ZENG; XIE, 2022).

Sistemas baseados em aprendizado de máquina permitem a personalização do tratamento de reabilitação, ajustando exercícios conforme a resposta do paciente. As RNNs têm sido objeto de pesquisas para prever a recuperação motora com base em dados de séries temporais, incluindo

dados recebidos de sensores de movimento (JIRAK et al., 2023).

Modelos de IA também são empregados em estudos relacionados ao diagnóstico precoce de doenças neuromusculares e condições motoras, como Parkinson, esclerose múltipla e lesões pós-AVC. Dados biomecânicos coletados por sensores ou extraídos de imagens podem ser analisados por modelos computacionais para identificar alterações sutis no movimento, contribuindo para intervenções mais rápidas e melhor acompanhamento clínico (ZHANG et al., 2023a).

Nos últimos anos, no contexto da telemedicina, modelos de aprendizado de máquina têm sido aplicados ao monitoramento remoto de pacientes. Dispositivos conectados a plataformas baseadas em IoT podem coletar dados de movimento para análise computacional, permitindo que profissionais da saúde acompanhem o progresso de pacientes fora do ambiente clínico, reduzindo custos e ampliando a conveniência do acompanhamento (ZHENG; JING; XU, 2019).

A reabilitação física e neurofuncional pode se beneficiar de sensores, vídeos e algoritmos de IA para medir e analisar movimentos, incluindo contextos específicos como a reabilitação pós-AVC. Alguns estudos têm apresentado como a análise detalhada dos movimentos pode fornecer dados relevantes sobre a recuperação do paciente, além de permitir a personalização dos programas de reabilitação (SEO et al., 2021; SHI et al., 2020b).

Em situações como a reabilitação após um AVC, por exemplo, os pacientes podem precisar reaprender determinados movimentos ou melhorar sua execução ao longo do tratamento. Técnicas de IA podem ser utilizadas para apoiar o monitoramento e a análise desses movimentos, auxiliando na identificação de características relevantes da execução motora e indicando aspectos que podem exigir maior atenção do profissional (JIRAK et al., 2023).

É importante auxiliar os programas de reabilitação a fim de maximizar a eficiência do acompanhamento e proporcionar melhores condições para a melhoria dos pacientes. Técnicas de aprendizado de máquina e aprendizado profundo são relevantes nesse contexto, pois podem apoiar análises preditivas e favorecer uma reabilitação mais personalizada (ZHENG; JING; XU, 2019).

Estudos anteriores também relataram o uso de jogos ativos e tecnologias interativas para aumentar a adesão e o engajamento dos pacientes na reabilitação (WANG et al., 2020; ALSOBHI et al., 2022). Em jogos sérios, por exemplo, o tempo para o paciente concluir determinada tarefa pode ser utilizado como um dos indicadores de desempenho, embora precise ser interpretado juntamente com outros aspectos do movimento (RODRIGUES, 2022).

Para que esses movimentos possam ser analisados computacionalmente, é necessário utilizar estratégias de captura capazes de registrar a execução motora e convertê-la em dados adequados para processamento.

2.5 Captura de Movimento por Vídeo e Sensores

Pesquisadores em diferentes contextos têm explorado o uso da visão computacional e da estimativa de pose para auxiliar na captura do movimento em reabilitação física e neurofuncional. A captura por vídeo se destaca por permitir o registro da execução motora sem a fixação obrigatória de sensores no corpo, o que pode facilitar a coleta em ambientes clínicos, ambulatoriais, domiciliares ou de pesquisa aplicada.

Segundo Miguel (MIGUEL, 2024), a captura por vídeo torna-se uma opção viável para que a aplicação não dependa de sensores vestíveis que podem ser invasivos para o paciente. Em sua pesquisa, é possível verificar que os pontos corporais são capturados por meio do MediaPipe. Essa abordagem se relaciona com propostas que buscam tornar a análise do movimento mais acessível, portátil e menos dependente de equipamentos específicos.

A captura de movimento pode ocorrer por diferentes meios, incluindo sensores vestíveis, câmeras RGB, câmeras de profundidade e sistemas baseados em visão computacional. Cada abordagem apresenta vantagens e limitações. Sensores vestíveis podem fornecer medidas específicas, como aceleração, orientação ou atividade muscular, mas podem exigir preparação do paciente e interferir parcialmente na execução do movimento. Já a captura por vídeo tende a ser menos invasiva, embora dependa da qualidade da imagem, do posicionamento da câmera, da iluminação e da capacidade do algoritmo de estimar corretamente os pontos corporais.

Quando a captura é realizada por vídeo, as informações precisam ser trabalhadas antes de serem utilizadas na análise. O vídeo é decomposto em quadros, cada quadro é processado pelo estimador de pose e os pontos corporais identificados são armazenados com suas coordenadas e medidas de confiança. A partir desses pontos, são calculados ângulos articulares e medidas relacionadas à execução do protocolo, como amplitude, duração, trajetória aproximada e possíveis compensações. Assim, o vídeo funciona como fonte de dados para a obtenção de medidas quantitativas, e não apenas como registro visual da sessão.

Dispositivos como o Microsoft Kinect também tiveram destaque em pesquisas de reabilitação virtual, pois permitem interação corporal e acompanhamento de movimentos em ambientes terapêuticos. Esses dispositivos contribuíram para popularizar o uso de captura sem marcadores em aplicações de saúde e reabilitação, ainda que atualmente outras abordagens baseadas em visão computacional e estimativa de pose também sejam amplamente utilizadas (WANG et al., 2023).

Enquanto a prevenção de lesões é comum nos esportes, ela também é aplicável à saúde ocupacional. Movimentos e padrões repetitivos podem ser detectados por meio de sensores e algoritmos, destacando possíveis riscos de lesão e orientando mudanças na rotina do paciente ou trabalhador (BILESAN et al., 2019). Embora esse contexto não seja o foco principal deste trabalho, ele demonstra a amplitude de aplicações da análise de movimento em saúde.

A extração de pose a partir de vídeo tem avançado a ponto de permitir abordagens

mais acessíveis, portáteis e reproduzíveis. Em contextos de reabilitação, essa possibilidade é importante porque permite analisar a execução do movimento com critérios objetivos e com menor dependência de sensores acoplados ao corpo.

Independentemente do dispositivo utilizado, uma etapa central para a análise computacional do movimento é a representação do corpo humano por pontos anatômicos ou *landmarks*, que servem de base para o cálculo de ângulos, trajetórias e atributos cinemáticos.

2.6 Extração de Pose e Representação por Landmarks

Landmarks corporais são pontos de referência estimados sobre regiões anatômicas do corpo humano, como ombros, cotovelos, punhos, quadris, joelhos e tornozelos. A partir desses pontos, é possível representar computacionalmente a postura corporal ao longo do tempo e derivar medidas relacionadas ao movimento.

A extração de pose consiste em identificar esses pontos em imagens ou vídeos, geralmente quadro a quadro. Com isso, a execução do movimento passa a ser representada por uma sequência de posições corporais, que pode ser utilizada para calcular ângulos articulares, trajetórias, amplitudes, compensações e outros atributos relevantes para a análise.

Tsai e Huang (TSAI; HUANG, 2022) propõem a correção dos pontos do esqueleto corporal antes do reconhecimento do movimento, utilizando a simetria do corpo humano e restrições para identificar posições possivelmente incorretas. Esse procedimento busca reduzir os efeitos de erros na estimação dos pontos corporais e melhorar o desempenho do reconhecimento das ações.

No pipeline adotado pelo eMove, o pré-processamento também contempla o ajuste da orientação das séries angulares com base nos primeiros quadros da execução. Dependendo da disposição dos pontos corporais e do movimento analisado, alguns ângulos podem iniciar próximos de zero ou de cento e oitenta graus. Quando necessário, a orientação da curva é ajustada para manter uma leitura mais coerente entre as execuções de um mesmo movimento.

Em aplicações baseadas em vídeo, os pontos corporais estimados quadro a quadro podem ser utilizados para derivar informações cinemáticas, como ângulos articulares, trajetórias e variações temporais do movimento (DEBNATH et al., 2022; HELLSTEN et al., 2021; THARATIPYAKUL; SRIKAEWSIEW; PONGNUMKUL, 2024). Dessa forma, o vídeo atua como fonte para a extração dos dados, enquanto as etapas posteriores da análise podem se concentrar nas informações derivadas da execução motora.

A partir dos pontos corporais extraídos em cada quadro, o eMove calcula o ângulo da articulação principal e, quando configurado para o movimento analisado, o ângulo associado à compensação corporal. Esses dados são organizados juntamente com as informações temporais da execução, permitindo representar cada movimento como uma série de valores sincronizados

ao longo do tempo.

Essa organização entre pontos corporais, ângulos calculados e informações temporais permite comparar execuções, acompanhar variações e construir indicadores quantitativos para apoiar a avaliação da evolução funcional. Em uma repetição de elevação do braço, por exemplo, além de identificar que o membro foi elevado, podem ser observadas a amplitude alcançada, a duração da execução e a ocorrência de compensações em outras regiões do corpo (LIU et al., 2025).

Como os pontos e os ângulos são obtidos quadro a quadro, a execução do movimento passa a ser representada como uma sequência temporal. Diferentes repetições de uma mesma ação podem apresentar durações e velocidades distintas, mesmo quando mantêm um padrão motor semelhante. Por esse motivo, são necessárias técnicas capazes de comparar séries temporais considerando possíveis variações no ritmo de execução, como o Distorção Dinâmica do Tempo (*Dynamic Time Warping*) (DTW) (SAKOE; CHIBA, 1978; MÜLLER, 2007).

2.7 Séries Temporais e Alinhamento Temporal

Em problemas de análise de movimento, o tempo de execução e a velocidade de uma mesma ação podem variar entre diferentes repetições, mesmo quando o padrão motor observado é semelhante. Nesses casos, medidas ponto a ponto, como a distância Euclidiana direta entre séries, tendem a superestimar dissimilaridades causadas apenas por deformações na dimensão temporal.

O DTW é uma técnica utilizada para comparar séries temporais que podem apresentar diferenças de duração ou velocidade de execução. O método realiza um alinhamento entre as sequências, permitindo identificar padrões semelhantes mesmo quando eles ocorrem em ritmos distintos (SAKOE; CHIBA, 1978; MÜLLER, 2007).

De forma intuitiva, o DTW busca a melhor correspondência entre duas sequências, permitindo esticar ou comprimir trechos localmente para minimizar o custo total de dissimilaridade, respeitando a ordem temporal dos eventos. Esse alinhamento é obtido por programação dinâmica e resulta em uma distância que quantifica a semelhança entre as séries analisadas (MÜLLER, 2007). O caminho ótimo pode ser recuperado por retrocesso, permitindo comparar segmentos executados em velocidades distintas desde que a forma geral do movimento seja preservada (SAKOE; CHIBA, 1978; BERNDT; CLIFFORD, 1994).

Embora seja uma técnica eficaz para comparar séries temporais, o DTW apresenta limitações relacionadas à flexibilidade do alinhamento entre as sequências. Para minimizar esse efeito, a literatura propõe estratégias que restringem o alinhamento durante o processo de comparação (SAKOE; CHIBA, 1978; ITAKURA, 1975; MÜLLER, 2007).

Estudos sobre mineração e classificação de séries temporais demonstram que o DTW

apresenta bom desempenho na comparação de sequências sujeitas a variações de fase e velocidade, tornando-se útil em tarefas de busca por similaridade, agrupamento e reconhecimento de padrões (BERNDT; CLIFFORD, 1994; KEOGH; RATANAMAHATANA, 2005).

No contexto da análise de movimento humano, o DTW possibilita comparar repetições executadas em ritmos diferentes, desde que mantenham um padrão motor semelhante. Dessa forma, pode contribuir para identificar execuções consistentes, detectar variações clínicas ou compensatórias e apoiar etapas posteriores de agrupamento, classificação e curadoria.

2.8 Agrupamento, Classificação e Curadoria Especializada

O agrupamento de movimentos permite organizar execuções semelhantes sem depender, inicialmente, de rótulos previamente definidos (FRANGOUDES et al., 2022). Em contextos de reabilitação, essa abordagem pode auxiliar na identificação de padrões recorrentes, execuções atípicas e variações entre repetições realizadas por um mesmo paciente ou por pacientes diferentes.

A classificação busca associar uma execução a uma categoria previamente conhecida, podendo utilizar atributos extraídos do movimento, como amplitude, duração, compensação e medidas de similaridade. Em aplicações de apoio à saúde, essa classificação deve ser interpretada como recurso auxiliar, e não como decisão automática isolada (BENSALAH et al., 2022; SHORTLIFFE; SEPÚLVEDA, 2018).

Uma vez delimitadas, as repetições podem ser tratadas como unidades analíticas, permitindo extrair medidas específicas de cada execução e realizar comparações dentro da mesma sessão ou entre sessões distintas do paciente. Após a segmentação, cada repetição pode ser representada por atributos como amplitude do movimento principal, amplitude compensatória, duração e medidas de proximidade com uma referência derivadas do alinhamento temporal (FRANGOUDES et al., 2022).

Essas informações podem indicar o número de repetições reconhecidas em cada sessão, a duração média, a variação entre mínimos e máximos da articulação em foco e possíveis diferenças em relação a uma execução de referência. Com isso, o profissional pode observar padrões de melhoria, compensação ou inconsistência durante o tratamento (BENSALAH et al., 2022; FRANGOUDES et al., 2022).

A curadoria especializada é fundamental nesse processo, pois o profissional pode revisar agrupamentos, validar classificações e ajustar interpretações com base em conhecimento clínico e funcional. Dessa forma, os métodos computacionais atuam como apoio à organização e análise dos dados, preservando o papel do especialista na interpretação final (SHORTLIFFE; SEPÚLVEDA, 2018; MILLER, 2019).

Essa relação entre agrupamento, classificação e curadoria reforça que sistemas de apoio à

saúde devem oferecer informações organizadas, rastreáveis e compreensíveis, sem serem tratados como mecanismos automáticos de decisão. Como os resultados gerados podem influenciar a interpretação profissional, torna-se necessário considerar aspectos de transparência, rastreabilidade e explicabilidade (GUNNING; AHA, 2019; MILLER, 2019).

2.9 Interpretabilidade e Explicabilidade em Sistemas de Apoio à Saúde

Em sistemas de apoio à saúde, a interpretabilidade está relacionada à possibilidade de compreender quais informações influenciam uma análise ou recomendação. Já a explicabilidade busca tornar mais claros os mecanismos que levam um modelo computacional a determinado resultado. Embora esses conceitos estejam relacionados, ambos são importantes para aumentar a confiança, a transparência e a segurança no uso de tecnologias computacionais em contextos sensíveis.

Nesse contexto, o uso de abordagens de Inteligência Artificial Explicável (*Explainable Artificial Intelligence*) (XAI) pode contribuir para proporcionar maior transparência aos modelos aplicados à saúde. Isso é importante para auxiliar a equipe e os pacientes a entenderem os resultados apresentados pela tecnologia, favorecendo maior confiança e aceitação dessas abordagens (ZENG; XIE, 2022).

No contexto da análise de movimentos humanos, atributos como amplitude, duração, compensação e similaridade em relação a uma execução de referência podem fornecer indicadores quantitativos sobre o desempenho motor (ULLAH et al., 2025; LIU et al., 2025). Quando apresentados de forma compreensível, esses atributos também podem apoiar a interpretação dos resultados e a revisão das classificações ou dos agrupamentos sugeridos pelo sistema (MILLER, 2019).

Entretanto, a apresentação de resultados computacionais não garante, por si só, sua compreensão clínica ou sua validade terapêutica. Em sistemas aplicados à saúde, as informações produzidas pelos modelos devem ser interpretadas em conjunto com o conhecimento especializado e com o contexto clínico e funcional de cada paciente (SHORTLIFFE; SEPÚLVEDA, 2018).

A interpretabilidade constitui, portanto, um elemento complementar às técnicas de análise, classificação e agrupamento. Seu objetivo é tornar os resultados mais compreensíveis e úteis para o profissional, mantendo o sistema computacional como recurso de apoio, e não como substituto da avaliação especializada (MILLER, 2019; SHORTLIFFE; SEPÚLVEDA, 2018).

2.10 Considerações Finais

Este capítulo apresentou os principais conceitos relacionados à aplicação de IA, aprendizado de máquina e análise computacional de movimentos humanos no contexto da saúde e da reabilitação física e neurofuncional.

Foram discutidos aspectos relacionados à captura de movimentos por vídeo e sensores, extração de pose, representação por *landmarks*, séries temporais, alinhamento temporal, classificação, agrupamento, curadoria especializada e interpretabilidade em sistemas de apoio à saúde. Esses conceitos são importantes para compreender como movimentos humanos podem ser registrados, representados, comparados e analisados por métodos computacionais.

Apesar dos avanços consideráveis na área, a diversidade de abordagens, aplicações e contextos indica a necessidade de organizar as evidências existentes, compreender limitações metodológicas e identificar lacunas relevantes para o desenvolvimento deste trabalho.

Com base nesses conceitos, o próximo capítulo apresenta a metodologia utilizada para conduzir a revisão sistemática da literatura, buscando identificar estudos relacionados à análise, classificação e representação computacional de movimentos humanos no contexto da saúde e da reabilitação.

3 Revisão Sistemática da Literatura

Este capítulo apresenta a metodologia utilizada para conduzir a revisão sistemática da literatura. A revisão foi organizada com o objetivo de identificar estudos relacionados à análise computacional, classificação e representação de movimentos humanos no contexto da saúde, com atenção especial para aplicações em reabilitação física e neurofuncional.

A proposta deste capítulo é descrever o processo adotado para localizar, selecionar e organizar os estudos utilizados na revisão. Os resultados obtidos a partir da leitura e análise dos trabalhos selecionados são apresentados no Capítulo 4.

3.1 Planejamento da Revisão

A revisão sistemática foi adotada como método para organizar evidências científicas relacionadas ao tema deste trabalho. Esse tipo de revisão utiliza a literatura existente sobre um tópico específico como fonte de dados, permitindo reunir, comparar e sintetizar contribuições relevantes a partir de uma estratégia previamente definida (SAMPAIO, 2007).

Segundo Boland (BOLAND, 2013), uma revisão sistemática envolve etapas como planejamento da pesquisa, definição da questão, escolha das fontes de busca, triagem dos estudos, leitura completa, avaliação dos trabalhos, extração de dados, síntese das evidências e apresentação dos resultados. Essas etapas ajudam a tornar o processo mais claro e rastreável.

Neste trabalho apresentado, a revisão foi planejada para apoiar a construção da fundamentação conceitual e metodológica da solução proposta. O interesse principal foi identificar como diferentes estudos representam, capturam, analisam e classificam movimentos humanos, especialmente em contextos relacionados à reabilitação, avaliação da evolução funcional e uso de técnicas computacionais.

A revisão também foi utilizada para compreender quais tecnologias aparecem com maior frequência nos estudos, quais formas de captura são utilizadas, quais abordagens de modelagem são adotadas e quais lacunas podem orientar o desenvolvimento do eMove.

3.2 Questão de Pesquisa

A questão de pesquisa foi definida com base no objetivo de compreender como métodos computacionais têm sido utilizados para apoiar a análise e a classificação de movimentos humanos em contextos de saúde e reabilitação.

A questão central adotada foi:

> Como técnicas computacionais, incluindo aprendizado de máquina, visão computacional e métodos de classificação, têm sido aplicadas na análise e classificação de movimentos humanos em contextos de reabilitação física e neurofuncional?

Essa formulação amplia o foco em relação à proposta inicial, que estava mais concentrada em reabilitação pós-AVC e em XAI. A reabilitação pós-AVC continua sendo considerada como um contexto possível dentro da revisão, mas não como o único recorte do trabalho. Essa mudança foi importante para aproximar a revisão do escopo atual da dissertação, que trata da análise computacional de movimentos humanos em reabilitação física e neurofuncional.

3.3 Bases de Dados Consultadas

Para realizar a busca dos estudos, foram utilizadas bases científicas disponíveis por meio do acesso institucional da Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP), incluindo recursos acessados via conexão Rede Virtual Privada (*Virtual Private Network*) (VPN). As bases consultadas foram Associação para Maquinaria da Computação (*Association for Computing Machinery*) (ACM), Portal Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Instituto de Engenheiros Elétricos e Eletrônicos (*Institute of Electrical and Electronic Engineers*) (IEEE).

A ACM foi utilizada por sua relevância na área da computação, reunindo publicações de conferências, periódicos, revistas técnicas, boletins e livros relacionados a diferentes áreas da ciência da computação (ACM, 2024).

O Portal CAPES foi utilizado por oferecer acesso a uma ampla coleção científica nacional e internacional, incluindo periódicos, bases de dados, teses, dissertações, livros, normas técnicas e outros tipos de produção acadêmica (CAPES, 2024).

A base IEEE foi considerada por concentrar publicações relevantes nas áreas de engenharia, computação, eletrônica, sensores, aprendizado de máquina e sistemas aplicados à saúde (IEEE, 2024).

Essas bases foram escolhidas por cobrirem tanto estudos computacionais quanto pesquisas aplicadas envolvendo sensores, visão computacional, aprendizado de máquina, classificação de movimentos e tecnologias de apoio à saúde.

3.4 Estratégia de Busca

Durante o planejamento da revisão, foram avaliadas diferentes combinações de palavras-chave para encontrar uma estratégia compatível com o objetivo do trabalho. As primeiras buscas estavam mais centradas em reabilitação pós-AVC e em XAI. No entanto, esse recorte limitava a

quantidade de estudos relacionados a outras formas de análise computacional de movimentos humanos.

Por esse motivo, a estratégia final de busca foi ampliada para contemplar termos relacionados à reabilitação, métodos computacionais, inteligência artificial, visão computacional, suporte à fisioterapia, desenvolvimento de software e neuroreabilitação. Essa escolha permitiu recuperar estudos mais próximos do escopo atual da dissertação.

A estrutura final utilizada na busca é apresentada na Tabela 1.

Tabela 1 – Estratégia final de busca utilizada na revisão sistemática

PALAVRAS-CHAVE	post-stroke rehabilitation, computational methods, artificial intelligence, medical rehabilitation, computer vision, physical therapy support, software development, neurorehabilitation
ESTRUTURA DE BUSCA	("post-stroke rehabilitation"AND "computational methods") OR ("artificial intelligence"AND "medical rehabilitation") OR ("computer vision"AND "physical therapy support") OR ("software development"AND "neurorehabilitation")
PERÍODO CONSIDERADO	Estudos publicados a partir de 01/01/2019
BASES CONSULTADAS	ACM, Portal CAPES e IEEE

Fonte: Autor

Com a aplicação dessa estratégia, foram identificados inicialmente 90 trabalhos. A distribuição dos documentos retornados em cada base científica é apresentada na Tabela 2.

Tabela 2 – Quantidade de documentos retornados por base científica

Base Científica	**ACM**	**CAPES**	**IEEE**	**Total**
Documentos retornados	34	37	19	90

Fonte: Autor

3.5 Critérios de Inclusão e Exclusão

Os critérios de inclusão e exclusão foram definidos para selecionar estudos com relação direta com o objetivo da revisão. Foram priorizados trabalhos que apresentavam métodos, técnicas, bases de dados, formas de captura ou abordagens computacionais aplicadas à análise de movimentos humanos.

Foram considerados como critérios de inclusão:

- estudos publicados a partir de 2019;
- estudos relacionados à análise, reconhecimento ou classificação de movimentos humanos;

- estudos com aplicação em saúde, reabilitação, avaliação da evolução funcional ou análise de atividade humana;
- estudos que utilizassem técnicas computacionais, como aprendizado de máquina, aprendizado profundo, visão computacional, sensores ou métodos de processamento de sinais; e
- estudos que apresentassem informações sobre dados, forma de captura, tecnologias utilizadas ou abordagem aplicada.

Foram considerados como critérios de exclusão:

- estudos duplicados;
- estudos fora do período definido;
- trabalhos sem relação direta com análise de movimento humano;
- estudos que não apresentavam aplicação ou contribuição relevante para saúde ou reabilitação;
- trabalhos que não disponibilizavam informações suficientes sobre dados, método, tecnologia ou abordagem utilizada; e
- estudos cujo foco principal estivesse distante do objetivo da dissertação.

Esses critérios foram aplicados em etapas. Primeiro, foram removidos os estudos duplicados. Depois, os resumos foram avaliados para verificar aderência ao tema. Por fim, os trabalhos restantes foram lidos integralmente para confirmação da relevância.

3.6 Processo de Seleção dos Estudos

O processo de seleção dos estudos foi organizado em três etapas principais: remoção de duplicidades, leitura dos resumos e leitura completa dos trabalhos.

Para permitir o controle dos artigos, cada estudo recebeu um identificador sequencial no momento do registro em planilha. Esse controle facilitou a conferência dos dados, a remoção de duplicidades e o acompanhamento das decisões tomadas durante a triagem.

Inicialmente, foram identificados 90 estudos. Após a verificação de duplicidades, 2 trabalhos foram removidos, restando 88 artigos para leitura dos resumos. Nessa etapa, 50 estudos foram excluídos por não atenderem aos critérios definidos, resultando em 38 trabalhos selecionados para leitura completa.

Na etapa de leitura completa, 15 artigos foram removidos por não apresentarem aderência suficiente ao objetivo da revisão ou por não fornecerem informações adequadas para a extração dos dados. Ao final do processo, 23 estudos foram aprovados para compor a revisão sistemática.

A Tabela 3 resume o fluxo de seleção adotado.

Tabela 3 – Resumo do processo de seleção dos estudos

Etapa	**Quantidade**	**Descrição**
Estudos identificados inicialmente	90	Trabalhos retornados nas bases ACM, Portal CAPES e IEEE.
Duplicados removidos	2	Estudos repetidos identificados na organização inicial.
Estudos após remoção de duplicados	88	Trabalhos encaminhados para leitura dos resumos.
Removidos após leitura dos resumos	50	Estudos sem aderência suficiente aos critérios definidos.
Selecionados para leitura completa	38	Estudos avaliados integralmente.
Removidos após leitura completa	15	Trabalhos removidos por baixa aderência ou informações insuficientes.
Estudos selecionados para a revisão	23	Trabalhos finais utilizados na análise da revisão sistemática.

Fonte: Autor

A seleção final representa o conjunto de estudos considerados relevantes para analisar técnicas, tecnologias, dados e abordagens computacionais aplicadas ao movimento humano em contextos relacionados à saúde e reabilitação.

3.7 Dados Extraídos dos Estudos

A partir da leitura dos estudos selecionados, foram extraídas informações consideradas relevantes para responder à questão de pesquisa e apoiar a análise apresentada no Capítulo 4.

Os dados extraídos foram organizados em uma planilha de controle, permitindo comparar os estudos de forma mais clara. As informações consideradas foram:

- **Título do artigo**: identificação completa do trabalho selecionado;
- **Autores**: nomes dos autores de cada estudo;
- **Ano de publicação**: ano em que o trabalho foi publicado;
- **Fonte de publicação**: base científica ou veículo de publicação do estudo;
- **Origem do conjunto de dados**: identificação se os dados foram produzidos pelos autores ou obtidos de bases já existentes;

- **Tipo de captura**: forma utilizada para obtenção dos dados, como sensores, câmeras, sinais musculares, imagens, vídeos ou outros dispositivos;
- **Conjunto de dados utilizado**: base ou amostra empregada no estudo;
- **Tecnologias e ferramentas**: linguagens, bibliotecas, frameworks, sensores ou recursos computacionais utilizados;
- **Abordagens aplicadas**: técnicas de análise, classificação, reconhecimento, agrupamento ou modelagem utilizadas.

Esses campos foram escolhidos porque permitem observar não apenas o resultado final de cada estudo, mas também como os dados foram capturados, representados e processados. Para este trabalho, essa distinção é importante, pois a proposta do eMove depende justamente da relação entre captura, representação do movimento, extração de atributos e análise computacional.

3.8 Síntese e Organização dos Dados

Após a extração, os dados foram organizados de forma comparativa. A análise buscou identificar padrões entre os estudos, considerando o tipo de dado utilizado, a forma de captura, as tecnologias empregadas e as técnicas aplicadas à classificação ou análise dos movimentos.

A síntese dos dados foi conduzida de forma qualitativa, agrupando os estudos por características em comum. Essa organização permitiu observar tendências da literatura, como o uso de sensores vestíveis, câmeras, sinais de sEMG, estimativa de pose, aprendizado profundo, técnicas de classificação e abordagens para reconhecimento de atividades humanas.

Também foram observadas lacunas relacionadas à disponibilidade de dados, à explicação dos resultados, à aplicação em contextos reais de reabilitação e à participação dos profissionais da saúde (especialistas em Cinesiologia) na interpretação das informações geradas. Esses pontos são discutidos no Capítulo 4, juntamente com a caracterização dos estudos selecionados.

A Tabela 4 apresenta uma síntese geral da metodologia aplicada nesta revisão. Esta tabela permanece no Capítulo 3 por resumir o percurso metodológico da revisão, enquanto a relação nominal dos estudos selecionados e as análises por categoria são apresentadas no Capítulo 4.

Tabela 4 – Síntese metodológica da revisão sistemática

Tipo de revisão	Revisão sistemática da literatura
Tema central	Análise computacional e classificação de movimentos humanos em contextos de saúde e reabilitação
Questão de pesquisa	Como técnicas computacionais, incluindo aprendizado de máquina, visão computacional e métodos de classificação, têm sido aplicadas na análise e classificação de movimentos humanos em contextos de reabilitação física e neurofuncional?
Bases consultadas	ACM, Portal CAPES e IEEE
Período considerado	Estudos publicados a partir de 2019
Estudos identificados	90
Duplicados removidos	2
Removidos após leitura dos resumos	50
Removidos após leitura completa	15
Estudos selecionados	23
Dados extraídos	Título, autores, ano, fonte, origem dos dados, tipo de captura, conjunto de dados, tecnologias/ferramentas e abordagens aplicadas
Forma de síntese	Organização qualitativa e comparativa dos estudos selecionados

Fonte: Autor

3.9 Considerações Finais

Este capítulo apresentou a metodologia adotada para a condução da revisão sistemática da literatura. Foram descritos o planejamento da revisão, a questão de pesquisa, as bases científicas consultadas, a estratégia de busca, os critérios de inclusão e exclusão, o processo de seleção dos estudos, os dados extraídos e a forma de organização da síntese.

A revisão resultou em 23 estudos selecionados a partir de 90 trabalhos inicialmente identificados. Esse conjunto de estudos constitui a base para a análise apresentada no próximo capítulo, no qual são discutidas as tecnologias, métodos, formas de captura e abordagens computacionais encontradas na literatura.

No Capítulo 4, os estudos selecionados são analisados com maior detalhe, buscando compreender como a literatura tem tratado a captura, representação, classificação e análise de movimentos humanos em contextos relacionados à saúde e à reabilitação física e neurofuncional.

4 Resultados da Revisão Sistemática

Este capítulo apresenta os resultados obtidos a partir da análise dos 23 estudos selecionados na revisão sistemática. Diferente do capítulo anterior, que descreveu o percurso metodológico da revisão, este capítulo se concentra nos achados observados nos trabalhos analisados.

A organização dos resultados foi feita a partir dos dados extraídos dos estudos, considerando a origem dos conjuntos de dados, as estratégias de captura, a natureza das atividades analisadas, as tecnologias utilizadas, as abordagens computacionais aplicadas e as lacunas identificadas. Ao final, são discutidas as implicações desses resultados para a concepção e o desenvolvimento do eMove.

4.1 Caracterização Geral dos Estudos Selecionados

A revisão sistemática resultou em 23 estudos selecionados para análise. Esses trabalhos foram considerados relevantes por apresentarem relação com análise, captura, reconhecimento ou classificação de movimentos humanos, especialmente em contextos associados à saúde, reabilitação, atividades humanas, sensores, visão computacional e técnicas de aprendizado de máquina.

A Tabela 5 apresenta os estudos selecionados, indicando a referência utilizada, o título do trabalho e a fonte de origem. Essa tabela tem a finalidade de oferecer uma visão geral dos trabalhos que compõem o corpus da revisão, permitindo ao leitor identificar rapidamente quais estudos foram considerados nas análises seguintes.

Além da identificação dos trabalhos, também foi analisada a distribuição temporal dos estudos selecionados. Essa análise permite observar se o tema apresenta concentração em determinados anos e ajuda a compreender a desenvolvimento recente das pesquisas sobre análise computacional de movimentos humanos.

Tabela 5 – Artigos selecionados na revisão sistemática

Autor (Ano)	**Título**	**Fonte**
(GEMAN et al., 2019)	An Intelligent Assistive Tool Using Exergaming and Response Surface Methodology for Patients With Brain Disorders	IEEE
(ZHENG; JING; XU, 2019)	Action Recognition Based on Spatial Temporal Graph Convolutional Networks	ACM
(MORANDO; TROMBINI; DELLEPIANE, 2019)	Application of SVM for Evaluation of Training Performance in Exergames for Motion Rehabilitation	ACM
(BILESAN et al., 2019)	Markerless Human Motion Tracking Using Microsoft Kinect SDK and Inverse Kinematics	IEEE
(CASTILLO et al., 2019)	Optimization Model for Development of Digital Interactive Exercises for Cognitive Rehabilitation	IEEE
(WANG et al., 2019)	Surface Electromyography Based Estimation of Knee Joint Angle by Using Correlation Dimension of Wavelet Coefficient	IEEE
(LI et al., 2019)	Skeleton-Based Action Recognition With Key-Segment Descriptor and Temporal Step Matrix Model	IEEE
(WANG et al., 2020)	Dense Attention Network for Facial Expression Recognition in the Wild	ACM
(SHI et al., 2020a)	Gait recognition via random forests based on wearable inertial measurement unit	CAPES
(SU; SU, 2020)	Intelligent Medical Rehabilitation Training Instrument Based on Movement Coordination	IEEE
(SHI et al., 2020b)	Feature Extraction and Classification of Lower Limb Motion Based on sEMG Signals	IEEE
(SEO et al., 2021)	Forecasting the Walking Assistance Rehabilitation Level of Stroke Patients Using Artificial Intelligence	CAPES
(MU; DAI; MA, 2021)	Application of Artificial Intelligence in Rehabilitation Assessment	CAPES

Continua na próxima página

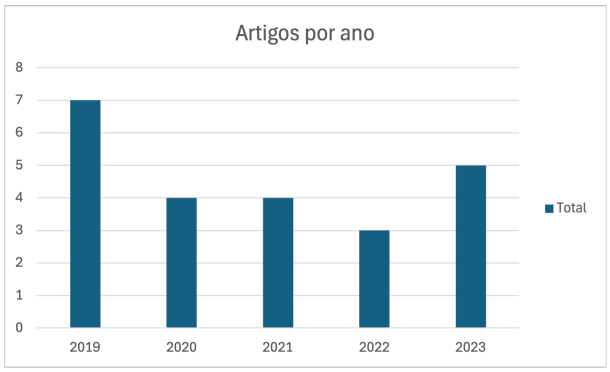
Tabela 5 – *Artigos selecionados na revisão sistemática (continuação)*

Autor (Ano)	**Título**	**Fonte**
(HE et al., 2021)	Flexible and stretchable triboelectric nanogenerator fabric for biomechanical energy harvesting and self-powered dual-mode human motion monitoring	CAPES
(SOCCINI; CENA, 2021)	The Ethics of Rehabilitation in Virtual Reality: the role of Self-Avatars and Deep Learning	IEEE
(RAO, 2022)	Research on Different Convolutional Neural Networks in the Classification Scenes of Yoga Poses based on OpenPose Extraction	IEEE
(TSAI; HUANG, 2022)	Temporal-Variation Skeleton Point Correction Algorithm for Improved Accuracy of Human Action Recognition	CAPES
(ZENG; XIE, 2022)	Upper-limb Movement Classification using sEMG Signals Based on Deep Residual Shrink Network	IEEE
(JIRAK et al., 2023)	Echo State Networks and Long Short-Term Memory for Continuous Gesture Recognition: a Comparative Study	CAPES
(ZHANG et al., 2023b)	A human activity recognition method using wearable sensors based on convtransformer model	CAPES
(ZHANG et al., 2023a)	An end-to-end lower limb activity recognition framework based on sEMG data augmentation and enhanced CapsNet	CAPES
(WANG et al., 2023)	Attention-based Vision Transformer for Human Activity Classification using mmWave Radar	ACM
(WU, 2023)	Evaluation on Multimodal Dance Action Recognition Based on Artificial Intelligence Image Technology	ACM

Fonte: Autor

A Figura 1 apresenta a quantidade de estudos selecionados por ano. Observa-se que os trabalhos aparecem distribuídos ao longo dos anos considerados na revisão, indicando continuidade de interesse pelo tema. O ano de 2019 concentrou a maior quantidade de estudos aprovados, seguido por trabalhos publicados nos anos seguintes.

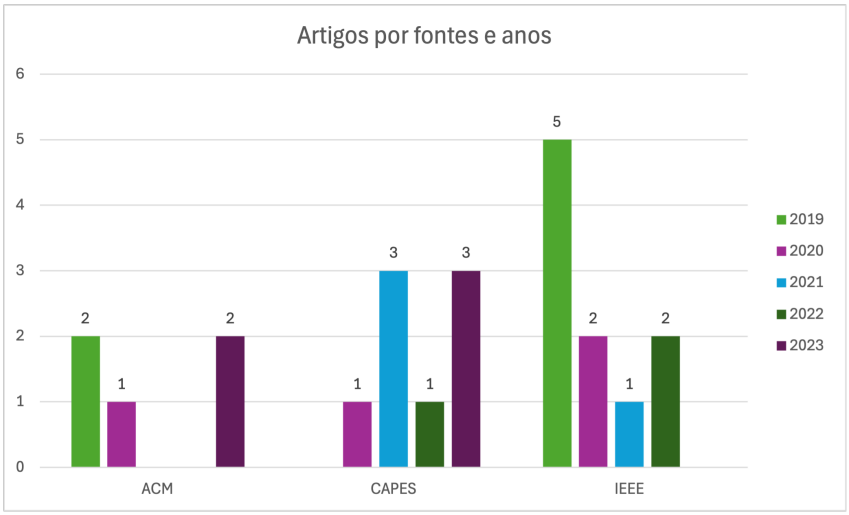
Figura 1 – Gráfico de artigos por ano aprovados



Fonte: Autor

Também foi analisada a distribuição dos artigos por fonte e ano, conforme apresentado na Figura 2. Essa visualização permite identificar como as bases consultadas contribuíram para o conjunto final de estudos selecionados.

Figura 2 – Gráfico de artigos por fonte e ano



Fonte: Autor

A distribuição por fonte indica que os estudos selecionados foram encontrados em diferentes bases, o que reforça a característica interdisciplinar do tema. A análise de movimentos humanos aparece tanto em publicações mais ligadas à computação quanto em bases que reúnem pesquisas aplicadas à saúde, sensores, engenharia e reabilitação.

4.2 Origem dos Conjuntos de Dados e Estratégias de Coleta

A primeira dimensão analisada foi a origem dos conjuntos de dados utilizados nos estudos. Esse ponto é importante porque a qualidade, o tamanho e a forma de construção do conjunto de

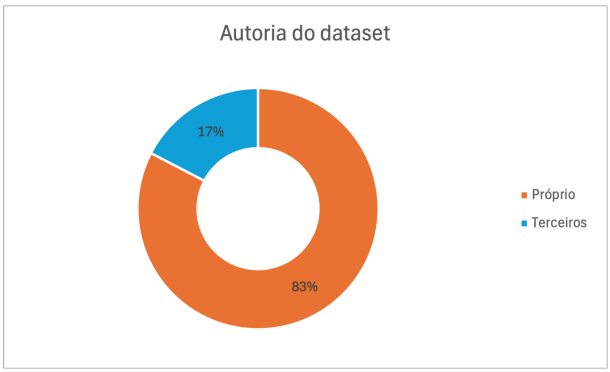
dados influenciam diretamente o desempenho de modelos de classificação, reconhecimento e análise de movimentos.

Nos trabalhos analisados, os conjuntos de dados foram classificados em dois grupos principais:

- **Próprio**: quando os autores coletaram os dados utilizados no estudo, como imagens, vídeos, sinais de sensores ou outros registros de movimento;
- **Terceiros**: quando os autores utilizaram conjuntos de dados previamente construídos e disponibilizados por outros pesquisadores.

A distribuição dos estudos de acordo com a origem dos conjuntos de dados é apresentada na Figura 3.

Figura 3 – Autoria do conjunto de dados



Fonte: Autor

A maior parte dos estudos analisados utilizou conjuntos de dados próprios. Esse resultado mostra que muitos pesquisadores precisaram construir suas próprias bases para responder aos objetivos específicos de seus estudos. Em pesquisas envolvendo movimento humano, isso é comum, pois o tipo de movimento, o público analisado, o sensor utilizado e o protocolo de coleta costumam variar bastante.

Por outro lado, a presença de conjuntos de dados de terceiros também é relevante. Bases públicas ou já consolidadas permitem comparações entre métodos e facilitam a reprodução dos experimentos. Mesmo assim, a disponibilidade de conjuntos de dados específicos para reabilitação ainda é limitada, principalmente quando se deseja analisar movimentos clínicos, compensações ou melhoria funcional do paciente.

Entre os conjuntos de dados de terceiros observados nos estudos, destacam-se:

- **UCF-101 e UCF-31**: utilizados em tarefas de reconhecimento de ações humanas em vídeo, com diferentes categorias de atividades e cenários (WANG et al., 2023);

- **AffectNet**: utilizado em reconhecimento de expressões faciais e estados emocionais, com aplicação mais distante do foco específico da reabilitação motora (WANG et al., 2020);
- **Northwestern-UCLA, MSRC-12 e CAD-60**: usados em tarefas de reconhecimento de ações baseadas em dados esqueléticos e poses em 3D (ZHENG; JING; XU, 2019);
- **OPPORTUNITY, PAMAP2, SKODA e USC-HAD**: utilizados em reconhecimento de atividades humanas com sensores vestíveis, como acelerômetros e giroscópios (ZENG; XIE, 2022).

Essa diferença entre bases próprias e bases de terceiros aponta uma questão importante para este trabalho: em aplicações voltadas à reabilitação física e neurofuncional, muitas vezes é necessário organizar dados próximos do contexto real de atendimento. Uma base genérica pode ajudar no desenvolvimento de modelos, mas pode não representar adequadamente a execução de movimentos específicos de um paciente em tratamento.

4.3 Modalidades de Captura e Representação dos Movimentos

Os mecanismos de captura utilizados nos estudos analisados demonstram uma separação importante entre abordagens baseadas em vídeo, sensores vestíveis, sinais musculares, imagens estáticas e dispositivos específicos de captura.

Os estudos baseados em vídeo exploram a possibilidade de capturar ações humanas em diferentes ambientes. Essa abordagem é útil por ser menos invasiva, mas também pode apresentar limitações relacionadas à privacidade, iluminação, posicionamento da câmera e qualidade da estimativa dos pontos corporais (ZHENG; JING; XU, 2019).

Sensores vestíveis, como acelerômetros e giroscópios, aparecem como uma alternativa bastante utilizada. Eles podem ser integrados ao corpo ou a dispositivos móveis, permitindo registrar aceleração, orientação e velocidade angular durante a execução de atividades. Conjuntos como OPPORTUNITY e PAMAP2 exemplificam o uso desse tipo de dado para reconhecimento de atividades humanas (ZENG; XIE, 2022).

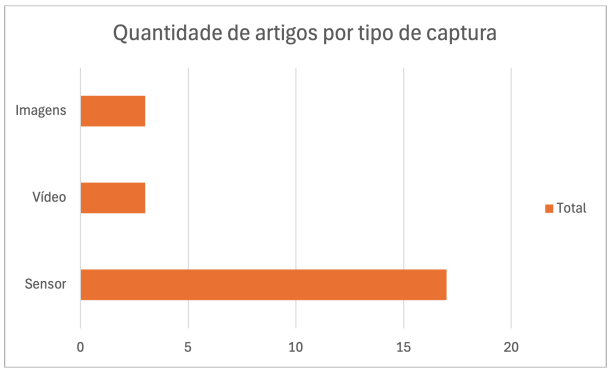
Outro recurso observado foi o uso de IMU, que integra acelerômetros, giroscópios e, em alguns casos, magnetômetros. Esse tipo de sensor permite medir orientação, aceleração e velocidade angular, sendo aplicado, por exemplo, na identificação de gestos contínuos das mãos com base em modelos recorrentes (JIRAK et al., 2023).

A técnica de sEMG também apareceu nos estudos analisados. Ela permite obter sinais elétricos gerados pela atividade muscular durante o movimento, sendo utilizada em pesquisas sobre membros superiores e inferiores. Em tarefas como caminhada, levantamento de pernas e classificação de movimentos musculares, esse tipo de dado pode fornecer informações biomecânicas importantes (ZENG; XIE, 2022; ZHANG et al., 2023a).

Também foram identificados estudos com dispositivos como Microsoft Kinect e Leap Motion. O Kinect foi utilizado para captura de movimento esquelético sem marcadores, enquanto o Leap Motion apareceu em aplicações voltadas à captura detalhada de movimentos das mãos, especialmente em contextos relacionados à reabilitação (ZHENG; JING; XU, 2019; MORANDO; TROMBINI; DELLEPIANE, 2019).

A Figura 4 apresenta a distribuição dos estudos segundo o tipo de captura utilizado. Os sensores aparecem como a modalidade mais frequente entre os estudos aprovados. Esse resultado mostra uma preferência por dispositivos capazes de registrar dados de movimento com boa precisão e de forma contínua. A captura por vídeo aparece em menor quantidade, mas permanece relevante por permitir uma abordagem menos invasiva, principalmente quando associada à estimativa de pose e à representação por pontos corporais.

Figura 4 – Quantidade de artigos por tipo de captura



Fonte: Autor

Essa distribuição reforça que não existe uma única forma de capturar o movimento humano. Cada modalidade apresenta vantagens e limitações. Para o eMove, esse resultado é importante porque evidencia o espaço para soluções baseadas em vídeo e visão computacional, especialmente quando o objetivo é reduzir dependência de sensores acoplados ao corpo e facilitar a coleta em ambientes mais acessíveis.

4.4 Natureza das Atividades e Contextos de Aplicação

A natureza das atividades analisadas nos estudos foi classificada em três categorias gerais: atividades discretas, contínuas e mistas. Essa distinção ajuda a compreender o tipo de movimento que cada estudo buscou reconhecer ou analisar.

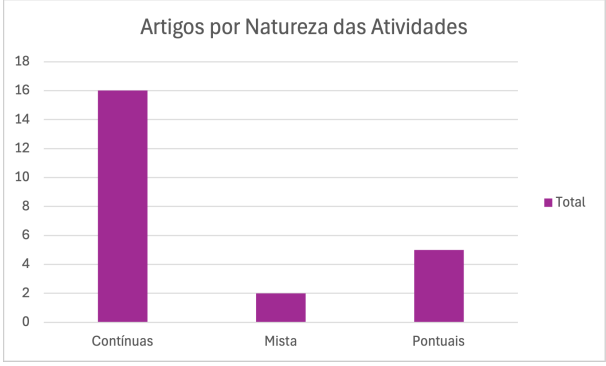
As atividades discretas correspondem a ações delimitadas, como um gesto específico ou uma repetição isolada. Esse tipo de atividade aparece, por exemplo, em estudos que analisam movimentos das mãos por sensores IMU, nos quais gestos de curta duração podem ser registrados com maior precisão (JIRAK et al., 2023).

As atividades contínuas envolvem séries de movimentos prolongados ou executados ao longo do tempo, como caminhar, correr ou realizar atividades diárias. Conjuntos como OPPORTUNITY e PAMAP2 representam bem esse tipo de abordagem, pois registram atividades do cotidiano por meio de sensores vestíveis (ZENG; XIE, 2022).

As atividades mistas combinam elementos discretos e contínuos. Esse tipo de dado é encontrado em estudos com movimentos esqueléticos, como nos conjuntos Northwestern-UCLA e MSRC-12, que podem incluir ações individuais e sequências dinâmicas mais complexas (ZHENG; JING; XU, 2019).

A Figura 5 apresenta a distribuição dos artigos conforme a natureza das atividades analisadas.

Figura 5 – Quantidade de artigos por natureza das atividades



Fonte: Autor

A predominância de atividades contínuas indica que muitos estudos se concentram em movimentos prolongados ou em atividades acompanhadas ao longo do tempo. Isso é relevante para aplicações gerais de reconhecimento de atividades humanas. No entanto, para o contexto de reabilitação, movimentos discretos e repetitivos também têm papel importante, pois muitos exercícios terapêuticos são organizados por repetições de um gesto ou movimento articular.

Essa observação se aproxima da proposta do eMove. Em uma sessão de reabilitação, o profissional pode precisar analisar não apenas o comportamento global da sessão, mas cada repetição realizada pelo paciente. Uma sequência contínua pode parecer estável, mas algumas repetições específicas podem indicar fadiga, perda de amplitude ou compensação.

4.5 Tecnologias, Ferramentas e Técnicas Computacionais

As tecnologias e ferramentas utilizadas nos estudos também foram analisadas. Entre as linguagens de programação, o Python apareceu com destaque, especialmente por sua ampla adoção em projetos de aprendizado de máquina, aprendizado profundo e processamento de dados.

A Tabela 6 apresenta as tecnologias identificadas nos estudos selecionados. Entre os estudos categorizados como baseados em Python, destacam-se bibliotecas como TensorFlow (ZHANG et al., 2023b), PyTorch (JIRAK et al., 2023) e Keras (ZHANG et al., 2023a), frequentemente utilizadas em tarefas de treinamento e avaliação de modelos.

Tabela 6 – Tecnologias identificadas nos estudos selecionados

Tecnologia	**Quantidade**
Python	10
MATLAB	6
COMSOL	1
Kinect SDK	2
Não especificado	3
Unity	1

Fonte: Autor

Ferramentas como MATLAB também foram observadas em estudos que exigiam cálculos matemáticos, processamento de sinais e análise de dados biomecânicos (LI et al., 2019; SHI et al., 2020b). O COMSOL apareceu em pesquisas voltadas à simulação de sensores e sistemas biomecânicos, principalmente em contextos de validação de dispositivos vestíveis (HE et al., 2021).

Alguns estudos utilizaram sistemas e bibliotecas específicas para captura e processamento de movimentos, como o Microsoft Kinect SDK, aplicado à obtenção de dados esqueléticos e análise de movimentos em tempo real (BILESAN et al., 2019; GEMAN et al., 2019). Também foram identificadas ferramentas voltadas à simulação e ambientes imersivos, como o Unity, em estudos relacionados à realidade virtual e interação.

Em alguns trabalhos, as tecnologias utilizadas não foram descritas com muitos detalhes. Isso dificulta a reprodução dos experimentos e limita a comparação entre estudos. Para uma área que depende de dados, modelos e parâmetros computacionais, a ausência dessas informações pode prejudicar a compreensão do método adotado.

4.6 Abordagens de Modelagem, Classificação e Agrupamento

Os estudos analisados empregaram diferentes abordagens computacionais para reconhecimento, classificação e análise de movimentos humanos. Para fins de quantificação, os métodos foram classificados em duas categorias principais: aprendizado profundo e métodos clássicos de aprendizado de máquina, considerando a técnica predominante na etapa final de classificação.

As técnicas de aprendizado profundo apareceram com destaque, incluindo modelos baseados em CNN, RNN, redes recorrentes, modelos com atenção e arquiteturas baseadas em transformadores. Esses métodos são usados principalmente em tarefas com dados mais

complexos, como imagens, vídeos, séries temporais e reconhecimento contínuo de atividades (ZENG; XIE, 2022; JIRAK et al., 2023).

Métodos clássicos, como SVM, Random Forest e k-Vizinhos Mais Próximos (*k-Nearest Neighbors*) (k-NN), também foram utilizados. Essas abordagens aparecem especialmente em contextos com conjuntos de dados menores, dados tabulares ou características extraídas previamente. Em estudos com sensores vestíveis ou sinais musculares, por exemplo, métodos clássicos podem apresentar bons resultados quando os atributos extraídos representam bem o fenômeno analisado (ZHANG et al., 2023a).

Também foram identificadas abordagens híbridas, nas quais técnicas clássicas são empregadas no pré-processamento, na seleção de características ou em etapas auxiliares, enquanto modelos de aprendizado profundo são utilizados na etapa final de classificação (ZHENG; JING; XU, 2019).

A Tabela 7 apresenta a distribuição das abordagens identificadas nos estudos selecionados.

Tabela 7 – Abordagens identificadas nos estudos selecionados

Abordagem	**Percentual**
Aprendizado profundo	57%
Técnicas clássicas	43%

Fonte: Autor

Conforme apresentado na Tabela 7, as abordagens baseadas em aprendizado profundo foram predominantes entre os estudos analisados. Esse resultado acompanha a tendência observada na literatura de utilização de modelos mais complexos para tarefas de reconhecimento de padrões em imagens, vídeos e séries temporais.

Mesmo assim, a presença de métodos clássicos permanece relevante. Em muitos cenários, especialmente quando os dados são estruturados em atributos, modelos como SVM, Random Forest e k-NN continuam sendo alternativas úteis. Para aplicações em reabilitação, essa característica é importante porque atributos como amplitude, duração, compensação e similaridade podem ser interpretados com mais facilidade pelo profissional.

4.7 Desempenho dos Modelos

O desempenho dos modelos analisados nos estudos foi avaliado com base em métricas comuns em tarefas de aprendizado de máquina, como acurácia, precisão, revocação, F1-score e erro médio.

Modelos de aprendizado profundo apresentaram bons resultados em conjuntos de dados maiores e em tarefas mais complexas, como reconhecimento contínuo de atividades. Em alguns

estudos, modelos baseados em CNN alcançaram precisão superior a 95%, especialmente quando aplicados a conjuntos de dados bem anotados e com maior volume de informações (ZENG; XIE, 2022).

Em tarefas envolvendo séries temporais, modelos baseados em arquiteturas mais recentes também demonstraram bom desempenho, reduzindo erros em comparação com abordagens clássicas em determinados cenários (ZHENG; JING; XU, 2019). No entanto, esses resultados precisam ser interpretados considerando o tipo de dado, a base utilizada e a tarefa avaliada.

Métodos clássicos, como SVM e Random Forest, também apresentaram desempenho satisfatório em algumas tarefas, especialmente em conjuntos menores ou com características bem definidas. Estudos voltados ao reconhecimento de gestos simples indicaram que modelos clássicos podem atingir bons resultados quando a representação dos dados é adequada (JIRAK et al., 2023).

A escolha das métricas também variou conforme a natureza dos dados. Em tarefas de classificação, métricas como F1-score são úteis quando há desbalanceamento entre classes. Em análises baseadas em séries temporais ou previsão, medidas de erro podem ser mais adequadas. Essa diversidade mostra que a comparação direta entre estudos deve ser feita com cautela.

A Tabela 8 apresenta uma síntese dos resultados de desempenho observados nos estudos em que esse tipo de informação foi identificado de forma explícita durante a extração dos dados. Como os trabalhos utilizaram bases, tarefas, métricas e protocolos experimentais diferentes, os valores não devem ser interpretados como uma comparação direta entre métodos. A tabela tem a função de organizar os resultados reportados e evidenciar a heterogeneidade das avaliações encontradas na literatura.

Tabela 8 – Resultados de desempenho observados nos estudos da RSL quando reportados

Estudo	**Tarefa analisada**	**Métrica/resultado reportado**	**Observação para esta pesquisa**
(ZENG, 2022)	Reconhecimento multimodal de movimentos por imagem	Acurácia máxima de 95,1% e redução de tempo de execução em relação ao critério analisado	Indica o potencial de modelos baseados em imagens, mas em contexto distinto da reabilitação clínica.
(SHI et al., 2020a)	Reconhecimento de marcha com IMU	Acurácia média de 98,2% com Random Forest e validação cruzada	Mostra bom desempenho de métodos clássicos quando os atributos representam adequadamente o movimento.
(TSAI; HUANG, 2022)	Reconhecimento de ações humanas por esqueleto corporal	Aumento de acurácia em relação a modelos comparados após correção dos pontos do esqueleto	Reforça a importância da qualidade dos pontos corporais e do pré-processamento antes da classificação.
(JIRAK et al., 2023)	Reconhecimento contínuo de gestos com IMU	Desempenho comparável entre ESN e LSTM, com menor tempo de treinamento para ESN	Evidencia que séries temporais de movimento exigem avaliar desempenho e custo computacional.
(ZENG; XIE, 2022)	Classificação de movimentos de membros superiores com sEMG	Resultado de classificação com aprendizado profundo reportado pelo estudo	Aproxima-se do contexto de membros superiores, embora utilize sinais musculares em vez de vídeo.
(ZHANG et al., 2023b)	Reconhecimento de atividades humanas com sensores vestíveis	Avaliação de modelo baseado em ConvTransformer reportada pelo estudo	Indica uso de arquiteturas profundas em dados sequenciais, mas com dependência de sensores vestíveis.
(ZHANG et al., 2023a)	Reconhecimento de atividades de membros inferiores com sEMG	Avaliação de classificação com aumento de dados e CapsNet reportada pelo estudo	Reforça o uso de modelos complexos, mas também a necessidade de dados específicos e rotulados.
(MORANDO; TROMBINI; DELLEPIANE, 2019)	Avaliação de desempenho em exergames de reabilitação	Uso de SVM para avaliação de desempenho	Relaciona classificação computacional a atividades de reabilitação, mas em ambiente de exergame.

Fonte: Autor

Observa-se que os melhores valores numéricos foram obtidos em contextos específicos, com bases, sensores e tarefas próprias. Por esse motivo, esses resultados foram utilizados nesta dissertação como referência para compreender possibilidades e limitações metodológicas, e não como parâmetro direto de desempenho esperado para o eMove. Para a solução proposta, essa análise reforçou a decisão de adotar atributos interpretáveis, manter a curadoria especializada e avaliar os modelos conforme os dados efetivamente coletados no próprio contexto de uso.

4.8 Aplicações Práticas Identificadas

Os estudos analisados apresentaram aplicações em diferentes áreas, como saúde, reabilitação física, esportes, interação homem-máquina, segurança e reconhecimento de atividades humanas.

Na saúde, parte dos estudos investigou modelos aplicados ao monitoramento de pacientes em sessões de fisioterapia e reabilitação. Dispositivos vestíveis e sinais musculares, por exemplo, foram utilizados para analisar movimentos e identificar padrões inadequados, apoiando ajustes no plano terapêutico (ZENG; XIE, 2022; ZHANG et al., 2023a).

Ferramentas baseadas em sEMG também foram utilizadas para medir ativações musculares e apoiar análises relacionadas a deficiências motoras ou execução de movimentos (JIRAK et al., 2023). Em aplicações esportivas, estudos baseados em vídeo e captura de movimento permitiram analisar desempenho, otimizar gestos e prevenir lesões (ZHENG; JING; XU, 2019).

Na interação homem-máquina, modelos de reconhecimento de gestos foram utilizados para controlar dispositivos inteligentes, robôs, computadores ou sistemas baseados em IoT. Esse tipo de aplicação pode melhorar acessibilidade e usabilidade de tecnologias assistivas (WANG et al., 2023).

Embora algumas aplicações estejam fora do foco direto desta dissertação, elas ajudam a mostrar a amplitude do campo. Para o eMove, os estudos mais relevantes são aqueles que aproximam captura de movimento, análise computacional, reabilitação, avaliação da evolução funcional e apoio à interpretação profissional.

4.9 Síntese Comparativa dos Trabalhos Selecionados

A Tabela 9 apresenta uma visão mais detalhada dos estudos selecionados, cruzando cada trabalho com as perguntas usadas na extração dos dados. A intenção não é substituir a análise textual, mas deixar em um único lugar as respostas principais de cada artigo. Isso ajuda a visualizar, por exemplo, quais estudos usaram base própria, quais dependeram de sensores, quais trabalharam com atividades contínuas e quais abordagens computacionais foram mais utilizadas.

Ao observar a tabela detalhada, fica claro que a maioria dos estudos não trata a explicabilidade como eixo central. Mesmo quando utilizam modelos mais complexos, como redes profundas ou transformadores, os trabalhos tendem a priorizar desempenho, acurácia ou reconhecimento de padrões. Esse ponto é importante para este trabalho, pois reforça a necessidade de apresentar resultados de forma compreensível para o profissional, principalmente quando a análise envolve movimentos de pacientes em reabilitação.

A análise dos estudos permitiu observar alguns padrões importantes. O primeiro deles é a predominância de conjuntos de dados próprios, o que indica que muitos pesquisadores precisam construir suas próprias bases para avaliar movimentos específicos. Essa situação é compreensível, mas dificulta a comparação direta entre estudos.

O segundo ponto é a predominância de sensores como forma de captura. Sensores vestíveis, IMU e sEMG aparecem com frequência, principalmente por oferecerem medidas precisas e contínuas. Ao mesmo tempo, a captura por vídeo continua relevante por ser menos invasiva e por permitir abordagens baseadas em estimativa de pose.

O terceiro ponto é a forte presença de aprendizado profundo. Modelos baseados em CNN, RNN e transformadores aparecem como soluções frequentes para reconhecimento de atividades humanas e análise de movimentos. Mesmo assim, métodos clássicos continuam aparecendo,

especialmente quando os dados são organizados em atributos.

Tabela 9 – Síntese detalhada dos estudos selecionados conforme as perguntas da revisão

Estudo	Foco analisado	Q1 – Origem dos dados	Q2 – Captura	Q3 – Natureza	Q4 – Ferramentas	Q5 – Abordagem	Q6 – XAI
(WU, 2023)	Dança e reconhecimento multimodal	Próprio	Vídeo	Contínuas	MATLAB	Aprendizado profundo	Não aborda
(WANG et al., 2023)	Atividades humanas com radar	Próprio	Sinais de radar	Mista	MATLAB	Aprendizado profundo	Não aborda
(ZHENG; JING; XU, 2019)	Reconhecimento de atividades humanas	Terceiros: UCF-101 e UCF-31	Vídeo	Discretas	Python	Aprendizado profundo	Não aborda
(MORANDO; TROMBINI; DELLEPIANE, 2019)	Reabilitação motora em exergames	Próprio	Kinect e Leap Motion	Contínuas	Python	Clássico	Não aborda
(WANG et al., 2020)	Expressões faciais	Terceiros: AffectNet	Câmeras / imagens	Discretas	Python	Aprendizado profundo	Não aborda
(RAO, 2022)	Reconhecimento de poses de ioga	Próprio	Câmeras / imagens	Contínuas	Python	Aprendizado profundo	Não aborda
(BILESAN et al., 2019)	Movimento humano sem marcadores	Próprio	Kinect v2 e Vicon	Contínuas	Kinect SDK	Clássico	Não aborda
(SOCCINI; CENA, 2021)	Reabilitação com realidade virtual	Próprio	Sensores de VR	Contínuas	Unity	Aprendizado profundo	Não aborda
(SU; SU, 2020)	Reabilitação médica	Próprio	Sensores de movimento e EMG	Contínuas	Não especificado	Clássico	Não aborda
(CASTILLO et al., 2019)	Reabilitação cognitiva	Próprio	Câmeras / vídeo	Discretas	Não especificado	Clássico	Não aborda
(WANG et al., 2019)	Ângulo da articulação do joelho	Próprio	sEMG e Codamotion	Contínuas	MATLAB	Aprendizado profundo	Não aborda
(ZENG; XIE, 2022)	Movimentos dos membros superiores	Próprio	sEMG	Contínuas	MATLAB	Aprendizado profundo	Não aborda
(LI et al., 2019)	Ações humanas por dados de esqueleto	Terceiros: Northwestern-UCLA, MSRC-12 e CAD-60	Kinect / esqueleto	Mista	MATLAB	Clássico	Não aborda

Continua na próxima página

Tabela 9 – *Síntese detalhada dos estudos selecionados (continuação)*

Estudo	Foco analisado	Q1 – Origem dos dados	Q2 – Captura	Q3 – Natureza	Q4 – Ferramentas	Q5 – Abordagem	Q6 – XAI
(GEMAN et al., 2019)	Recuperação física e cognitiva	Próprio	Kinect	Contínuas	Kinect SDK	Clássico	Não aborda
(SHI et al., 2020b)	Movimentos dos membros inferiores	Próprio	sEMG	Contínuas	Não especificado	Aprendizado profundo	Não aborda
(MU; DAI; MA, 2021)	Avaliação em reabilitação médica	Próprio	sEMG	Contínuas	Não especificado	Clássico	Não aborda
(SEO et al., 2021)	Nível de assistência na marcha	Próprio	Dados clínicos e funcionais	Discretas	Python	Clássico	Não aborda
(JIRAK et al., 2023)	Reconhecimento contínuo de gestos	Próprio	IMU de smartphone	Contínuas	Python	Aprendizado profundo	Não aborda
(ZHANG et al., 2023b)	Reconhecimento de atividades humanas	Terceiros: OPPORTUNITY, PAMAP2, SKODA e USC-HAD	Sensores vestíveis	Contínuas	Python	Aprendizado profundo	Não aborda
(ZHANG et al., 2023a)	Atividades dos membros inferiores	Próprio	sEMG	Contínuas	Python	Aprendizado profundo	Não aborda
(SHI et al., 2020a)	Reconhecimento de marcha	Próprio	IMU	Contínuas	Python	Clássico	Não aborda
(TSAI; HUANG, 2022)	Reconhecimento de ações humanas	Próprio	Imagens contínuas / esqueleto	Contínuas	Python	Aprendizado profundo	Não aborda
(HE et al., 2021)	Monitoramento de movimento humano	Próprio	Sensores em tecido TENG	Discretas	COMSOL	Clássico	Não aborda

Fonte: Autor

A Tabela 10 resume os principais achados observados na revisão.

Tabela 10 – Síntese comparativa dos principais achados da revisão

Origem dos dados	Predomínio de conjuntos de dados próprios, com menor presença de bases de terceiros.
Captura dos movimentos	Maior uso de sensores vestíveis, IMU e sEMG, além de estudos com vídeo, Kinect, Leap Motion e imagens.
Natureza das atividades	Predomínio de atividades contínuas, mas com presença de atividades discretas e mistas.
Tecnologias	Uso frequente de Python, bibliotecas de aprendizado de máquina, MATLAB, Kinect SDK, Unity e ferramentas específicas de processamento.
Abordagens	Predomínio de aprendizado profundo, com uso complementar de métodos clássicos como SVM, Random Forest e k-NN.
Aplicações	Reabilitação, reconhecimento de atividades, análise de gestos, saúde, esportes, interação homem-máquina e segurança.
Limitações observadas	Dificuldade de comparação entre bases, pouca padronização, baixa explicabilidade em alguns estudos e distância entre experimentos controlados e uso real em reabilitação.

Fonte: Autor

4.10 Lacunas Identificadas na Literatura

A revisão permitiu identificar algumas lacunas relevantes para este trabalho. A primeira está relacionada à disponibilidade e padronização dos dados. Muitos estudos utilizam bases próprias, construídas para objetivos específicos. Isso dificulta a comparação entre métodos e limita a reprodução dos experimentos.

Outra lacuna envolve a distância entre experimentos computacionais e o contexto real de reabilitação. Muitos trabalhos apresentam bons resultados em bases controladas, mas nem sempre discutem como esses resultados seriam utilizados por profissionais da saúde (especialistas em Cinesiologia) durante o acompanhamento de um paciente.

Também foi observada limitação na explicação dos resultados. Modelos mais complexos, especialmente os de aprendizado profundo, podem alcançar alto desempenho, mas nem sempre apresentam informações suficientes para que os profissionais da saúde (especialistas em Cinesiologia) compreendam por que determinada classificação foi gerada.

Além disso, poucos estudos discutem a curadoria especializada como parte do processo. Em aplicações de saúde, a participação dos profissionais da saúde (especialistas em Cinesiologia) é essencial, pois a interpretação do movimento depende do contexto clínico, do histórico do paciente e dos objetivos do tratamento.

Por fim, a análise por repetição ainda aparece como uma necessidade importante. Muitos estudos tratam atividades ou sessões de forma global, mas em reabilitação uma mesma sessão

pode apresentar variações internas relevantes. Uma repetição pode ser bem executada, enquanto outra pode apresentar compensação, fadiga ou queda de amplitude.

4.11 Implicações dos Resultados da Revisão para o eMove

Os resultados da revisão sistemática contribuíram para orientar decisões relacionadas ao desenvolvimento do eMove. A predominância de sensores nos estudos evidencia sua relevância na literatura, mas também reforça a oportunidade de explorar alternativas baseadas em vídeo e visão computacional, com menor dependência de dispositivos acoplados ao corpo. Dessa forma, a revisão não foi utilizada apenas como contextualização teórica, mas também como base para a definição de requisitos da solução.

Outro ponto observado foi o uso recorrente de conjuntos de dados próprios. Em reabilitação física e neurofuncional, a coleta de dados tende a variar conforme o paciente, o movimento analisado e o objetivo terapêutico. Por isso, o eMove organiza as informações em diferentes níveis, considerando paciente, tratamento, movimento/protocolo, sessão e repetição.

A diversidade de métodos identificados na revisão, incluindo abordagens clássicas e de aprendizado profundo, indica que não há uma única estratégia computacional adequada para todos os cenários. Nesse sentido, o eMove prioriza a extração de atributos por repetição, como amplitude, compensação e duração, permitindo análises descritivas, estratégias de agrupamento e, futuramente, modelos supervisionados.

As lacunas relacionadas à explicabilidade e à curadoria foram consideradas como requisitos da proposta. Dessa forma, a classificação não é tratada como uma decisão final e automática, mas como um apoio à análise dos profissionais da saúde, especialmente especialistas em Cinesiologia. O sistema organiza informações, indicadores e comparações sobre os movimentos, permitindo que os resultados sugeridos sejam revisados, interpretados e ajustados quando necessário.

Por fim, a revisão reforçou a importância da análise por repetição. Ao dividir uma sessão em execuções individuais, torna-se possível observar variações internas que poderiam não ser percebidas em uma análise global. Esse aspecto se relaciona diretamente à proposta do eMove de apoiar a avaliação da evolução funcional de forma mais detalhada e rastreável.

Em síntese, os achados da RSL influenciaram requisitos como: permitir análise por vídeo, representar o movimento por pontos corporais e ângulos, configurar movimentos/protocolos, segmentar sessões em repetições, armazenar atributos por execução, oferecer saídas compreensíveis ao profissional e manter espaço para curadoria especializada. Esses requisitos são retomados no Capítulo 5, no qual são relacionados às decisões de arquitetura e ao pipeline de análise proposto.

4.12 Considerações Finais

Este capítulo apresentou os resultados da revisão sistemática da literatura, considerando os 23 estudos selecionados após o processo metodológico descrito no Capítulo 3. Os trabalhos foram analisados quanto à origem dos dados, aos tipos de captura, à natureza das atividades, às tecnologias utilizadas, às abordagens computacionais, ao desempenho dos modelos e às aplicações práticas.

Os resultados indicam predominância de conjuntos de dados próprios, forte presença de sensores vestíveis e uso expressivo de técnicas de aprendizado profundo. Ao mesmo tempo, métodos clássicos continuam relevantes, principalmente quando os movimentos são representados por atributos bem definidos.

A análise também evidenciou lacunas importantes, como a falta de padronização dos dados, a dificuldade de comparação entre estudos, a necessidade de maior explicabilidade e a pouca discussão sobre curadoria especializada. Esses aspectos ajudam a justificar decisões adotadas no eMove, especialmente a organização das informações por repetição, o uso de atributos interpretáveis e a manutenção dos profissionais da saúde (especialistas em Cinesiologia) como responsáveis pela análise final.

Com base nesses resultados, o próximo capítulo apresenta a arquitetura da solução e o pipeline de análise adotado no eMove, relacionando as evidências observadas na literatura com as decisões computacionais propostas neste trabalho.

5 Arquitetura da Solução e Pipeline de Análise

5.1 Visão Geral da Solução Proposta

Este capítulo apresenta a arquitetura da solução proposta e o pipeline de análise do eMove. A proposta foi organizada para apoiar a análise computacional de movimentos humanos em contextos de reabilitação física e neurofuncional, especialmente em situações nas quais os profissionais da saúde (especialistas em Cinesiologia) precisam acompanhar a execução dos movimentos de forma mais objetiva e registrar a melhoria do paciente ao longo do tempo.

O eMove foi concebido para apoiar a análise computacional de vídeos de movimento. Embora o vídeo já possa ser analisado visualmente pelos profissionais da saúde, o pipeline permite convertê-lo em dados estruturados para processamento computacional. Para isso, parte da captura ou importação do vídeo, realiza a extração da pose corporal, calcula ângulos articulares, organiza séries temporais, segmenta a sessão em repetições, extrai atributos e permite a organização das execuções por similaridade. A partir dessas etapas, a observação visual da sessão passa a ser complementada por medidas que podem ser revisadas, comparadas e registradas.

A proposta prioriza uma abordagem baseada em vídeo e estimação de pose, reduzindo a dependência obrigatória de sensores acoplados ao corpo. Essa escolha busca tornar a solução mais acessível para ambientes clínicos, ambulatoriais ou de pesquisa aplicada, sem desconsiderar as limitações desse tipo de captura, como iluminação, enquadramento, oclusões e qualidade da estimativa dos pontos corporais.

Além do processamento do movimento, a arquitetura também considera a organização longitudinal dos dados. Por isso, os registros são estruturados a partir da relação entre paciente, tratamento, movimento, sessão e repetição. Na terminologia adotada pelo sistema, o movimento representa a configuração computacional da tarefa analisada; na prática fisioterapêutica, essa configuração se aproxima de um protocolo, pois reúne a tarefa motora, os pontos corporais observados, os ângulos de interesse, as regras de segmentação, as métricas e os critérios de classificação. Essa organização permite que cada repetição analisada mantenha vínculo com seu contexto de origem, favorecendo a rastreabilidade e a comparação entre sessões.

Também foram considerados aspectos de privacidade, controle de acesso e proteção das informações sensíveis. Como o sistema lida com dados associados a pacientes, esses elementos não foram tratados apenas como recursos administrativos, mas como parte da concepção da solução.

O objetivo deste capítulo é apresentar a especificação do eMove. Os detalhes de imple-

mentação, telas, módulos desenvolvidos e recursos efetivamente construídos são apresentados no Capítulo 6.

5.2 Relação entre a Revisão Sistemática e as Decisões de Projeto

A RSL analisou vinte e três estudos relacionados à análise e classificação de movimentos humanos em contextos de saúde, reabilitação e monitoramento motor. Os trabalhos utilizaram diferentes formas de captura, como sensores vestíveis, sinais de sEMG, câmeras, câmeras de profundidade e técnicas de visão computacional, associadas a métodos clássicos e modernos de IA.

Os resultados da revisão indicaram que não existe uma única forma de representar ou analisar o movimento humano. Alguns estudos trabalham com sinais temporais, outros com imagens, esqueletos, pontos corporais, ângulos articulares ou atributos extraídos. Essa diversidade reforçou a necessidade de uma arquitetura flexível, capaz de representar o movimento em diferentes níveis, mas mantendo informações interpretáveis para os profissionais da saúde.

A primeira decisão de projeto foi priorizar a análise por vídeo comum e estimação de pose. Essa escolha foi motivada pela possibilidade de reduzir a dependência de equipamentos especializados, tornando o processo de coleta mais simples e menos invasivo. Mesmo assim, a arquitetura mantém a preocupação com a qualidade da captura, pois a estimativa de pose depende diretamente das condições do vídeo.

Outra decisão importante foi organizar a análise em nível de repetição, e não apenas da sessão completa. A sessão representa o conjunto da execução do exercício, mas pode reunir repetições com desempenhos diferentes entre si. Quando se avalia somente a sessão como um todo, variações relevantes podem ser diluídas ou ocultadas, como queda progressiva de amplitude, aumento de compensações, alteração no ritmo de execução ou diferenças entre as primeiras e as últimas repetições. Ao segmentar a sessão em repetições, o sistema permite observar cada execução de forma individualizada e comparar o comportamento do movimento ao longo da sessão, preservando informações que seriam menos evidentes em uma análise agregada.

Também foi considerada a variação natural de tempo entre execuções do mesmo movimento. Um paciente pode realizar uma repetição mais rápida e outra mais lenta, sem que isso signifique necessariamente um erro. Por isso, o pipeline considera séries temporais de ângulos e pode utilizar medidas de similaridade temporal, como o DTW, para comparar execuções com durações diferentes.

A Tabela 11 resume a relação entre algumas evidências observadas na revisão sistemática, os requisitos derivados dessas evidências e as decisões adotadas na arquitetura do eMove.

Tabela 11 – Relação entre evidências da RSL, requisitos e decisões de arquitetura do eMove

Evidência da RSL	**Implicação para o problema**	**Requisito derivado**	**Decisão de arquitetura no eMove**
Uso de diferentes formas de captura, como sensores vestíveis, sEMG, câmeras e visão computacional	A análise de movimento pode ser apoiada por métodos computacionais sem depender apenas de equipamentos especializados	Permitir entrada por vídeo comum e manter o pipeline independente de sensores obrigatórios	Adoção de uma arquitetura baseada em vídeo comum e estimação de pose, buscando facilitar o uso em ambientes clínicos ou ambulatoriais.
Estudos que analisam movimentos segmentados, articulações específicas ou fases da tarefa	Avaliações globais do gesto podem não capturar compensações ou variações em segmentos corporais específicos	Representar a sessão em repetições e associar cada repetição a articulações e ângulos configuráveis	Organização dos dados em séries temporais de ângulos por articulação, permitindo análise por repetição e por segmento corporal.
Variação natural de tempo entre execuções do mesmo movimento	Comparações diretas entre amostras podem ser frágeis quando a duração do movimento não é igual	Comparar execuções com durações diferentes sem exigir alinhamento ponto a ponto	Uso de medidas de similaridade temporal, como DTW, para comparar execuções com durações diferentes.
Predomínio de saídas numéricas ou classificações pouco explicadas em parte dos trabalhos	Os profissionais da saúde (especialistas em Cinesiologia) podem ter dificuldade em relacionar a saída do modelo com a interpretação clínica do movimento	Apresentar atributos compreensíveis, gráficos e relatórios revisáveis pelo profissional	Organização das saídas em métricas por repetição, gráficos, classificações e relatórios, favorecendo a leitura pelo profissional.
Soluções dependentes do contexto de coleta e de bases específicas	A análise automática precisa se adaptar à realidade de cada serviço, paciente e movimento	Permitir curadoria, rótulos manuais e reuso dos dados coletados no próprio contexto de aplicação	Inclusão de curadoria especializada, agrupamento por similaridade e classificação supervisionada com base nos dados coletados no próprio uso da solução.

Fonte: Autor

Outro ponto observado na RSL foi a dificuldade de transformar resultados computacionais em informações úteis para a prática profissional. Por isso, a arquitetura do eMove foi organizada em torno de atributos mais compreensíveis, como amplitude do movimento, duração da repetição, compensação, similaridade temporal e classificação por repetição.

Neste trabalho, a interpretabilidade é tratada como uma diretriz de projeto. O sistema ainda não utiliza, nesta etapa, técnicas formais de XAI, mas procura apresentar dados que possam ser compreendidos, revisados e contextualizados pelos profissionais da saúde (especialistas em Cinesiologia).

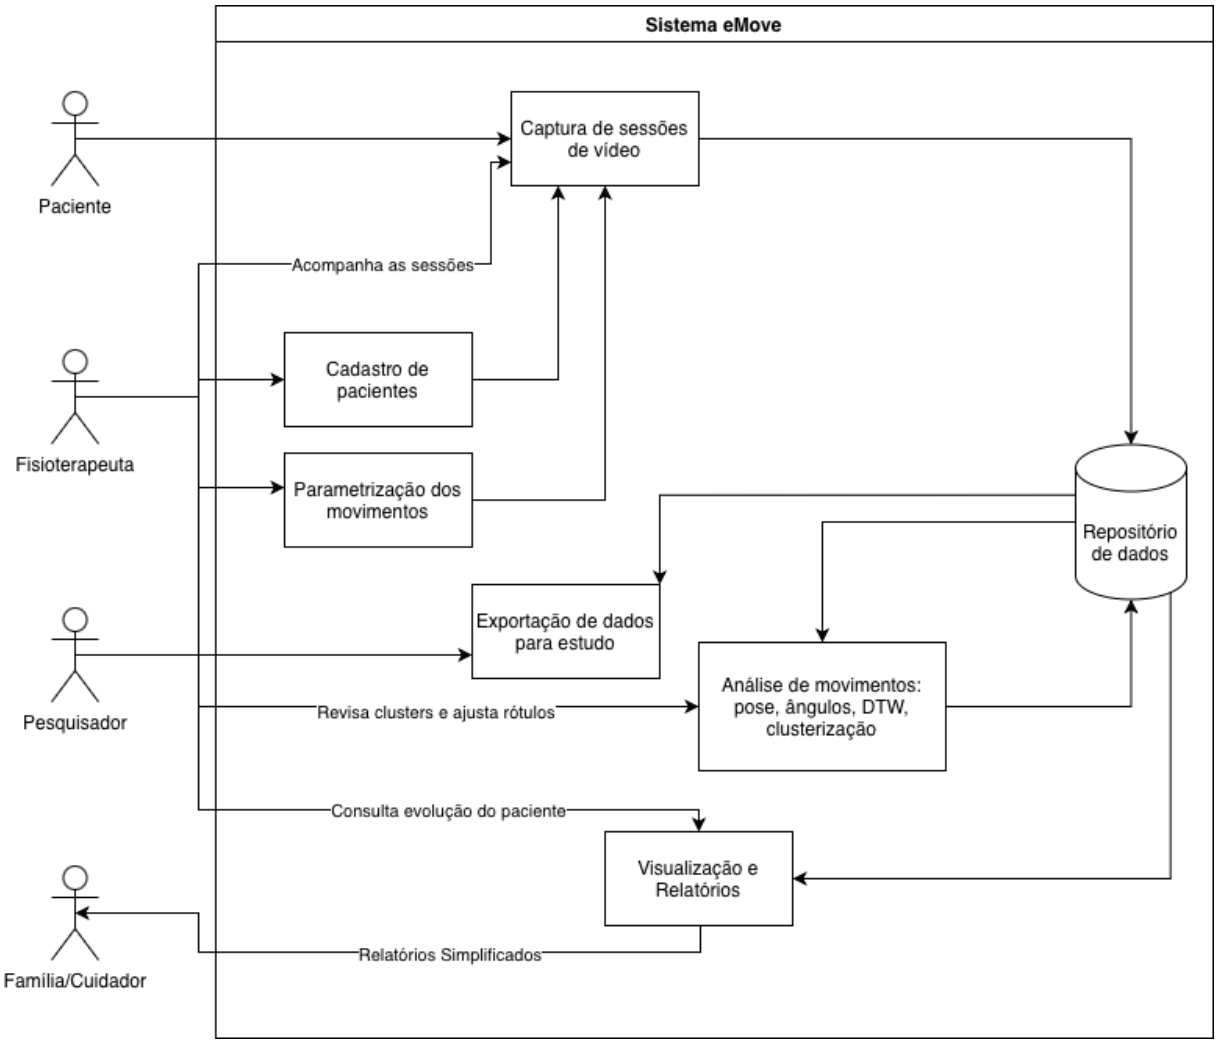
5.3 Arquitetura Geral e Modelo de Informação

A arquitetura geral do eMove segue uma sequência de etapas que transforma o vídeo em informações analisáveis. De forma resumida, o fluxo parte da captura ou importação de um

vídeo, passa pela extração de pose corporal, cálculo de ângulos, pré-processamento, segmentação em repetições, extração de atributos, organização por similaridade, classificação, geração de relatórios e persistência dos dados.

A Figura 6 apresenta uma visão funcional do eMove, destacando os principais atores que interagem com a solução e as funcionalidades envolvidas no fluxo de acompanhamento.

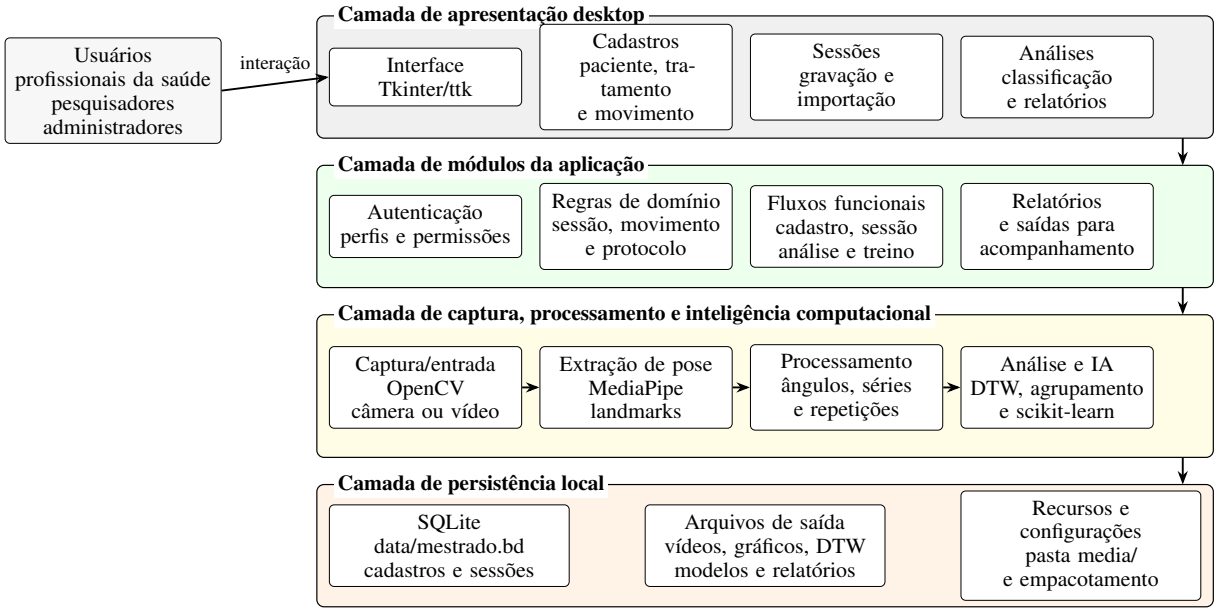
Figura 6 – Visão funcional do eMove, destacando os atores e as principais funcionalidades do sistema.



Fonte: Autor

Complementarmente, a Figura 7 apresenta a arquitetura técnica do eMove, implementada como uma aplicação desktop em Python. A representação organiza os principais componentes em camadas funcionais, separando a interação com o usuário, os módulos da aplicação, os recursos computacionais de captura e análise de movimento e os mecanismos locais de persistência em banco de dados e arquivos.

Figura 7 – Arquitetura técnica do eMove organizada em camadas funcionais



Fonte: Autor

No nível funcional, o eMove é organizado em módulos relacionados ao fluxo de acompanhamento. O módulo de cadastros concentra os registros de pacientes, tratamentos e movimentos/protocolos. O módulo de sessões organiza a gravação ou importação dos vídeos e associa cada coleta ao seu contexto de análise. O módulo de análise executa o pipeline computacional, incluindo extração de pose, cálculo de ângulos, segmentação em repetições, extração de atributos e classificação. Por fim, os módulos de relatórios e acompanhamento organizam os resultados obtidos em saídas revisáveis, permitindo consultar métricas, classificações, gráficos e registros associados às sessões analisadas.

O fluxo inicia com a definição do contexto de análise. Para que uma sessão seja interpretada corretamente, ela precisa estar relacionada a um paciente, a um tratamento, a um movimento e a um plano de gravação. Essa organização evita que os dados sejam analisados de forma isolada e permite acompanhar a evolução do paciente ao longo do tempo.

O paciente representa o indivíduo acompanhado. O tratamento fornece o contexto clínico ou terapêutico em que as sessões são realizadas. Essa separação é importante porque um mesmo paciente pode ter diferentes tratamentos ao longo do tempo, com objetivos e movimentos distintos.

O movimento representa a tarefa motora analisada. Para cada movimento, podem ser definidos os pontos corporais relevantes, as articulações de interesse, os ângulos calculados e as variáveis usadas na análise. Essa configuração é necessária porque cada exercício pode exigir medidas diferentes.

Embora o sistema utilize o termo movimento na interface e no modelo de dados, essa entidade também pode ser compreendida como um protocolo de análise. Seus elementos principais

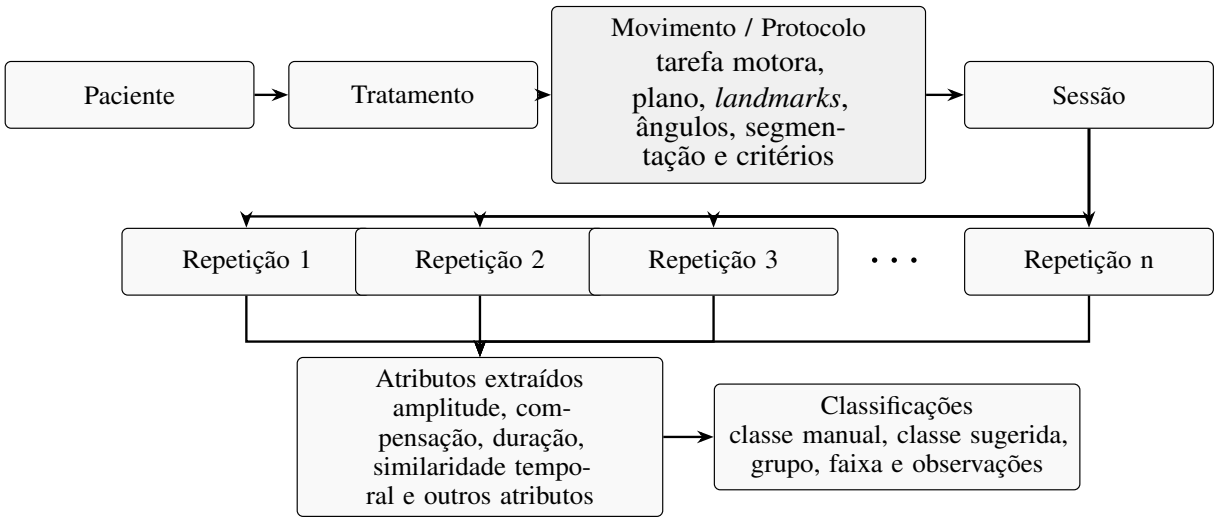
incluem a descrição da tarefa motora, o plano de gravação, os *landmarks* utilizados, o ângulo principal, as medidas de compensação, os parâmetros de segmentação, os atributos extraídos e os critérios de classificação ou curadoria. Essa definição torna o pipeline configurável, pois permite adaptar a análise a diferentes tarefas terapêuticas sem alterar a estrutura geral da aplicação.

A sessão corresponde a uma coleta específica de movimento, realizada por gravação direta ou importação de vídeo. Cada sessão pode conter uma ou mais repetições. A repetição é a unidade central de análise do pipeline, pois permite observar variações dentro da própria sessão e comparar execuções ao longo do tratamento.

Essa estrutura também contribui para a rastreabilidade. Como cada atributo calculado está associado a uma repetição, e cada repetição pertence a uma sessão, é possível recuperar o contexto em que determinada análise foi realizada, quais parâmetros foram utilizados e quais resultados foram obtidos.

A Figura 8 sintetiza essa organização hierárquica entre paciente, tratamento, movimento, sessão e repetição.

Figura 8 – Modelo de informação utilizado pelo eMove para organização do acompanhamento longitudinal



Fonte: Autor

5.4 Aquisição e Representação dos Dados de Movimento

O pipeline proposto utiliza vídeos contendo a execução do movimento, ou protocolo de análise, como fonte de entrada para análise. A partir desses vídeos, são aplicadas técnicas de estimação de pose capazes de identificar pontos corporais ao longo do tempo, permitindo transformar a execução motora em dados estruturados para processamento computacional.

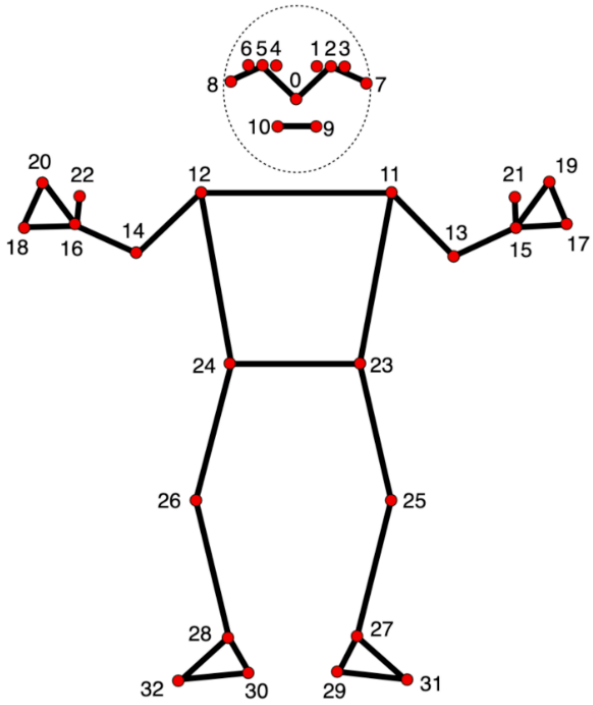
A extração de pose identifica pontos corporais em cada quadro do vídeo. Esses pontos, chamados de *landmarks*, representam regiões anatômicas ou articulares e servem como base

para o cálculo dos ângulos utilizados na análise dos movimentos.

Em um cenário típico, até 33 pontos podem ser obtidos para representar cabeça, tronco, membros superiores e membros inferiores. Cada ponto possui coordenadas no quadro e uma medida de confiança associada, permitindo identificar situações de rastreamento instável ou baixa qualidade da detecção.

A Figura 9 ilustra a topologia dos pontos corporais utilizados pelo modelo de estimação de pose.

Figura 9 – Conjunto de 33 *landmarks* corporais detectados pela MediaPipe Pose Landmarker.



Fonte: (Google AI Edge, 2026)

Neste trabalho, a análise é realizada principalmente a partir das coordenadas dos pontos corporais utilizados em cada movimento. Esses pontos são posteriormente empregados no cálculo dos ângulos articulares e na construção das séries temporais utilizadas pelas etapas subsequentes do pipeline.

Com essa representação, o movimento deixa de ser tratado apenas como uma sequência de imagens e passa a ser descrito por dados cinemáticos passíveis de armazenamento, comparação e processamento computacional.

5.5 Cálculo Cinemático e Pré-processamento das Séries Temporais

Após a extração dos pontos corporais, o sistema calcula ângulos articulares a partir de combinações de pontos definidos para cada movimento. Essa etapa transforma a pose estimada

em uma representação cinemática, permitindo analisar a variação angular ao longo do tempo.

Cada movimento pode exigir articulações diferentes. Um movimento de membro superior pode depender de ângulos relacionados ao ombro, cotovelo ou tronco, enquanto outros movimentos podem envolver articulações dos membros inferiores. Por isso, a arquitetura permite que os ângulos sejam definidos conforme a articulação e o plano de gravação considerados.

Além do ângulo principal do movimento, também podem ser calculadas medidas associadas à compensação. Essa possibilidade é importante porque, em reabilitação, o paciente pode realizar a tarefa com estratégias compensatórias, como inclinação do tronco, elevação do ombro ou uso excessivo de outro segmento corporal.

Os ângulos calculados ao longo dos quadros formam séries temporais. Essas séries são a base para as etapas seguintes do pipeline, como pré-processamento, segmentação, comparação temporal e extração de atributos.

O pré-processamento tem como objetivo preparar essas séries para uma análise mais estável. As curvas extraídas dos vídeos podem apresentar ruídos, pequenas oscilações e diferenças de orientação entre execuções.

Uma etapa importante é o ajuste da orientação do sinal. Em alguns movimentos, a curva pode iniciar em valores mais altos e depois diminuir; em outros, ocorre o contrário. Para evitar leituras invertidas, o sistema ajusta a direção das curvas quando necessário, buscando manter uma interpretação mais consistente entre execuções do mesmo movimento.

Também é aplicada uma suavização leve para reduzir pequenas flutuações produzidas pelo rastreamento de pose. O objetivo não é apenas melhorar a visualização da curva, mas reduzir a sensibilidade a ruídos de detecção, preservando os pontos principais da execução.

Quando necessário, também pode ser realizado um recorte da região de interesse do corpo no vídeo. Esse recorte concentra o processamento na região corporal analisada e reduz interferências do fundo da cena.

Com essas etapas, as séries temporais chegam à segmentação em uma condição mais adequada para comparação e extração de atributos.

5.6 Segmentação, Atributos e Organização por Similaridade

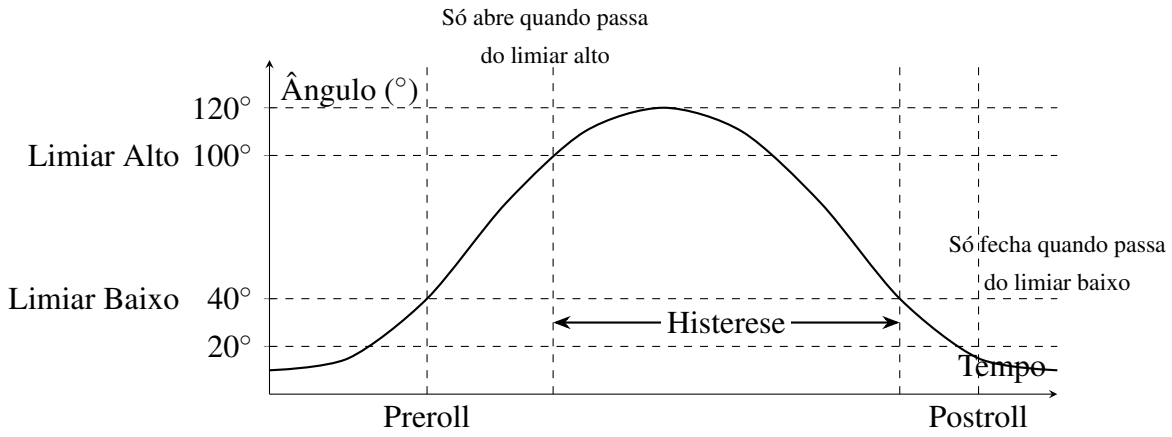
A segmentação separa a sessão em repetições individuais do movimento. Essa etapa é importante porque uma sessão completa pode conter várias execuções, e analisar apenas a sessão como um todo pode ocultar diferenças relevantes entre uma repetição e outra.

No eMove, a segmentação pode ser realizada com base em limiares e histerese aplicados à curva angular do movimento. A histerese utiliza dois limiares: um limiar alto, que indica a entrada na região ativa do gesto, e um limiar baixo, que indica o encerramento da execução.

Essa diferença evita que pequenas oscilações próximas ao limite façam a detecção abrir e fechar repetidamente.

A Figura 10 ilustra o funcionamento da histerese durante a segmentação de uma repetição, destacando os limiares utilizados, a região útil do movimento e as margens de *preroll* e *postroll*.

Figura 10 – Exemplo de curva de ângulo com limites de histerese, ilustrando *preroll*, região útil e *postroll*.



Fonte: Autor

O *preroll* preserva um intervalo antes do início detectado do gesto, enquanto o *postroll* mantém uma margem após o encerramento. Essas margens ajudam a preservar o contexto temporal da execução, evitando que o início ou o fim da repetição sejam cortados de forma excessiva.

Com a segmentação, cada repetição passa a ser tratada como uma unidade própria de análise. Isso permite calcular atributos individuais, comparar execuções entre si e acompanhar a variação do movimento ao longo da sessão ou do tratamento.

Entre os atributos considerados estão a amplitude do movimento, a duração da repetição, medidas associadas à compensação e medidas de similaridade temporal em relação a uma referência. Quando aplicável, as séries temporais de ângulos podem ser comparadas por meio do DTW, que permite alinhar execuções com durações diferentes e calcular uma distância entre elas.

A distância obtida pode ser utilizada como uma medida de similaridade entre a repetição analisada e uma referência. Repetições com menor distância tendem a apresentar comportamento temporal mais próximo da referência, enquanto distâncias maiores podem indicar variações de execução, compensações ou diferenças no ritmo do movimento.

Além das medidas temporais, atributos tabulares também são utilizados para representar cada repetição. Esses atributos são importantes porque aproximam a saída computacional de medidas mais compreensíveis, como amplitude, compensação e duração.

A organização das repetições por similaridade permite identificar execuções com características próximas. Essa etapa não tem como objetivo substituir a interpretação dos profissionais, mas apoiar a identificação de padrões de movimento, variações recorrentes e possíveis compensações.

5.7 Classificação, Agrupamento e Apoio à Curadoria

A classificação e o agrupamento são tratados como etapas de apoio à curadoria especializada. Os profissionais da saúde (especialistas em Cinesiologia) permanecem responsáveis pela interpretação final, revisando resultados, ajustando rótulos e validando as informações sugeridas pelo sistema.

Além do agrupamento e da classificação supervisionada, a arquitetura também prevê uma classificação por faixas, que associa atributos como a amplitude do movimento a intervalos previamente definidos para cada movimento. Essa abordagem oferece uma leitura inicial mais objetiva das repetições, sem depender de uma decisão automática mais complexa, complementando o agrupamento e a classificação supervisionada descritos a seguir.

O agrupamento automático organiza repetições semelhantes, permitindo observar padrões que poderiam ser menos evidentes em uma análise repetição por repetição. Os grupos formados podem ser revisados e interpretados pelo especialista, que pode atribuir nomes ou rótulos conforme a leitura funcional das execuções.

A classificação supervisionada, por sua vez, pode sugerir rótulos para novas execuções a partir de exemplos previamente curados. Nesse processo, os rótulos manuais atribuídos pelos profissionais da saúde são considerados referência para o treinamento e para a validação das sugestões automáticas.

Essa separação entre classe manual e classe sugerida é importante. A classe manual representa a decisão validada pelo especialista. A classe sugerida representa uma saída computacional de apoio. Dessa forma, o sistema não apresenta a classificação automática como decisão final.

A proposta é oferecer uma sugestão organizada, rastreável e revisável, que possa apoiar a análise das sessões e a construção de um histórico mais consistente do acompanhamento.

5.8 Saídas Analíticas, Relatórios e Governança dos Dados

As saídas do pipeline não se limitam às métricas internas do processamento. O objetivo é transformar os dados extraídos das sessões em informações que possam ser analisadas pelos profissionais da saúde e registradas ao longo do tratamento.

As saídas analíticas podem incluir gráficos de ângulos ao longo do tempo, atributos

por repetição, classificações, agrupamentos, observações e comparações entre sessões. Esses elementos ajudam a relacionar os dados computacionais à avaliação da evolução funcional do paciente.

Os relatórios de acompanhamento organizam essas informações de forma mais sintética. Eles podem reunir dados do paciente, tratamento, movimento analisado, sessões realizadas, métricas principais, classificações e observações. Com isso, o relatório fecha o ciclo do pipeline, levando os dados processados para uma forma mais adequada ao acompanhamento clínico, ambulatorial ou de pesquisa aplicada.

Também é importante considerar que os relatórios podem envolver informações sensíveis. Por isso, a geração dessas saídas deve respeitar mecanismos de privacidade, incluindo controle de acesso e possibilidade de proteção ou ocultação de dados identificáveis quando necessário.

A arquitetura do eMove considera aspectos de governança, privacidade e rastreabilidade desde sua concepção. Como o sistema pode lidar com dados de saúde, a proteção desses dados precisa ser pensada junto com o pipeline de análise, e não apenas como uma etapa posterior.

A rastreabilidade é mantida por meio do registro de sessões, parâmetros utilizados, atributos extraídos, classificações, rótulos manuais e resultados de análise. Essa organização permite reprocessar ou revisar uma sessão, identificar quais dados foram utilizados e compreender de onde surgiu uma determinada classificação ou relatório.

A privacidade é tratada por meio de decisões de arquitetura e de implementação. Entre elas estão o controle de acesso, a organização lógica dos dados, o compartilhamento controlado de pacientes e a possibilidade de proteger informações sensíveis em relatórios. Esses recursos são detalhados no Capítulo 6, mas fazem parte da concepção geral da solução.

5.9 Considerações Finais

Neste capítulo, a arquitetura da solução e o pipeline de análise do eMove foram apresentados como uma sequência de etapas que transforma dados de vídeo em informações analíticas. O fluxo parte da captura ou importação de vídeo, passa pela extração de pose, cálculo de ângulos, pré-processamento, segmentação em repetições, extração de atributos, organização por similaridade, classificação, geração de relatórios e persistência dos dados.

A estrutura proposta busca manter coerência entre os achados da revisão sistemática e as decisões adotadas no desenvolvimento do sistema. A opção por vídeo e estimação de pose busca reduzir a dependência de sensores especializados, enquanto a segmentação por repetição e a extração de atributos permitem uma análise mais detalhada das execuções motoras.

Também foram apresentados os elementos de apoio à curadoria especializada, incluindo agrupamento automático, classificação supervisionada e revisão dos resultados pelos profissionais da saúde. Por fim, foram discutidas as saídas analíticas, os relatórios e os aspectos de governança,

privacidade e rastreabilidade.

No próximo capítulo, são descritos os recursos implementados no eMove, mostrando como essa arquitetura foi materializada na aplicação.

6 Implementação e Recursos Desenvolvidos no eMove

6.1 Visão Geral da Implementação

Este capítulo apresenta a implementação do eMove e os principais módulos desenvolvidos para materializar a proposta apresentada no capítulo anterior. Enquanto o Capítulo 5 descreveu a arquitetura da solução e os elementos que compõem o pipeline de análise, este capítulo aborda os recursos efetivamente implementados na aplicação.

O desenvolvimento do sistema buscou integrar, em uma única plataforma, funcionalidades relacionadas ao gerenciamento de usuários, pacientes, tratamentos, sessões e movimentos, juntamente com os recursos necessários para aquisição, processamento, organização e análise dos dados gerados durante a execução dos movimentos.

Além dos componentes diretamente relacionados à análise computacional, também foram implementados recursos de apoio à utilização da aplicação, incluindo mecanismos administrativos, controle de acesso, geração de relatórios e funcionalidades voltadas à organização e ao acompanhamento longitudinal das avaliações realizadas.

Nas seções seguintes são apresentados os principais módulos desenvolvidos, sua organização funcional e sua contribuição para o fluxo de trabalho proposto para análise de movimentos em contextos de reabilitação física e neurofuncional.

6.2 Modelo de Dados e Organização do Acompanhamento

A implementação do eMove adota um modelo de dados voltado ao acompanhamento longitudinal dos pacientes. Em vez de tratar cada gravação como um registro isolado, a aplicação organiza as informações a partir da relação entre paciente, tratamento, movimento/protocolo, sessão e repetição, permitindo preservar o contexto de origem dos dados analisados.

Nesse modelo, os pacientes podem possuir diferentes tratamentos, cada tratamento pode conter múltiplas sessões e cada sessão está associada a um movimento previamente configurado. No contexto da aplicação, esse movimento corresponde à configuração do protocolo de análise, reunindo os pontos corporais, ângulos, parâmetros de segmentação e critérios utilizados no processamento. A partir das sessões registradas, o sistema identifica repetições individuais e armazena os atributos extraídos durante o processamento.

Essa organização permite relacionar análises realizadas em diferentes momentos, favorecendo a comparação entre sessões e o acompanhamento da evolução funcional ao longo do tempo.

Além disso, contribui para a rastreabilidade dos resultados, uma vez que atributos, classificações e demais informações produzidas pelo sistema permanecem vinculados ao contexto em que foram gerados.

A estrutura adotada também oferece suporte às etapas posteriores do pipeline, incluindo segmentação, classificação, agrupamento, treinamento supervisionado e geração de relatórios, mantendo a consistência dos dados utilizados durante todo o processo de análise.

6.3 Controle de Acesso, Multiempresa e Compartilhamento de Pacientes

A implementação do eMove inclui autenticação de usuários e controle de acesso, necessário porque o sistema manipula dados relacionados a pacientes, tratamentos e sessões, os quais exigem cuidado quanto à privacidade, rastreabilidade e acesso restrito. O login permite identificar o usuário responsável pelo acesso ao sistema e associar suas ações ao contexto adequado. A aplicação também foi evoluída para uma organização multiempresa, permitindo separar dados por instituição, clínica, laboratório ou grupo de pesquisa. Essa separação evita que informações de diferentes ambientes sejam misturadas.

Cada usuário pode estar vinculado a uma ou mais empresas, conforme as permissões configuradas. Com isso, o sistema consegue controlar quais pacientes, tratamentos e sessões estarão disponíveis para cada profissional. Essa estrutura também permite diferenciar perfis administrativos e operacionais, mantendo maior controle sobre cadastros, acessos e compartilhamentos.

Além da separação por empresa, o eMove implementa mecanismos de compartilhamento controlado de pacientes. Esse recurso permite colaboração entre profissionais da saúde sem perder a referência de origem do cadastro.

Um paciente pode permanecer vinculado a um responsável principal, mas ser compartilhado com outro profissional ou empresa quando houver necessidade de acompanhamento conjunto. Esse compartilhamento deve respeitar permissões definidas, evitando acesso indiscriminado aos dados.

Essa estratégia é importante em contextos de reabilitação, nos quais diferentes profissionais podem acompanhar o mesmo paciente em momentos distintos. Também é relevante em ambientes de pesquisa aplicada, nos quais os dados podem precisar ser acessados por uma equipe, mas com controle sobre quem pode visualizar ou editar informações.

O compartilhamento controlado permite equilibrar colaboração e privacidade. O sistema não trata os dados como informações abertas a todos os usuários, mas como registros sensíveis que precisam de regras claras de acesso.

Nesse processo, o paciente permanece vinculado à empresa de origem, mas pode ser disponibilizado para outros profissionais autorizados. Essa abordagem busca equilibrar colaboração e privacidade, permitindo acompanhamento conjunto sem comprometer o controle de acesso aos dados.

6.4 Aquisição, Importação e Processamento dos Dados de Movimento

O eMove foi desenvolvido para permitir tanto a captura direta de movimentos por câmera quanto a importação de vídeos previamente gravados. Essa abordagem amplia as possibilidades de utilização da aplicação, permitindo processar registros obtidos em diferentes contextos de atendimento, pesquisa ou acompanhamento clínico.

Independentemente da origem do vídeo, o sistema utiliza o mesmo fluxo de processamento e armazenamento dos dados gerados durante a análise. Essa abordagem permite manter consistência entre sessões capturadas diretamente pela aplicação e vídeos importados de outras fontes.

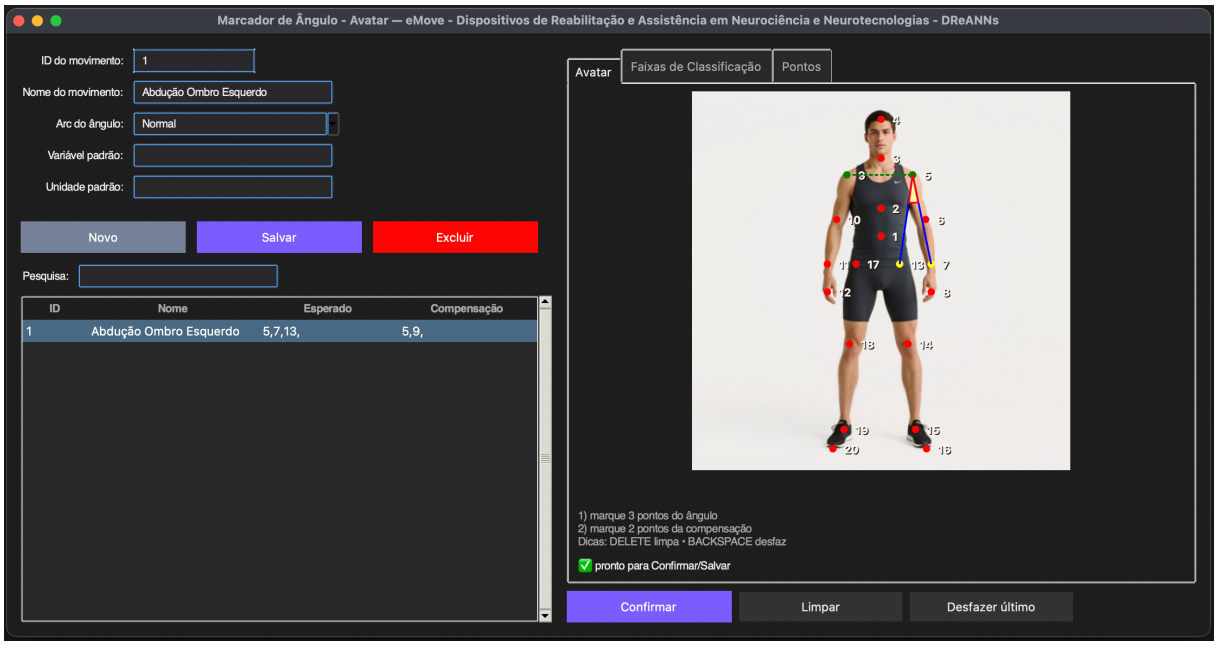
O processamento inicial dos vídeos utiliza a biblioteca Open Source Computer Vision Library (OpenCV), responsável pela leitura, decodificação e manipulação dos quadros de vídeo (OpenCV, 2026). Em seguida, o *MediaPipe Pose Landmarker* realiza a estimação da pose corporal, produzindo os *landmarks* utilizados nas etapas de cálculo dos ângulos articulares, segmentação das repetições e extração dos atributos empregados pelo pipeline de análise (Google AI Edge, 2026).

Para suportar diferentes exercícios sem necessidade de alterações na implementação, o sistema permite configurar os parâmetros associados a cada movimento, entendido também como protocolo de análise no contexto fisioterapêutico.

Por meio dessa parametrização, podem ser definidos os pontos corporais utilizados no cálculo do ângulo principal do movimento, bem como medidas complementares relacionadas à análise de compensações. Essa flexibilidade permite adaptar o processamento a diferentes articulações e tarefas motoras utilizando o mesmo pipeline computacional.

A Figura 11 apresenta a interface de cadastro de movimentos do eMove, utilizada para configurar os parâmetros associados a cada exercício/protocolo, incluindo os pontos corporais empregados no cálculo dos ângulos e das medidas de compensação.

Figura 11 – Interface de cadastro de movimentos no eMove



Fonte: Autor

Os dados gerados durante o processamento incluem informações derivadas da pose corporal, ângulos calculados e metadados associados à sessão. A persistência desses elementos permite revisar análises, realizar reprocessamentos e manter a rastreabilidade dos resultados produzidos ao longo do acompanhamento.

6.5 Segmentação Configurável e Atributos por Repetição

O eMove implementa segmentação configurável por sessão, permitindo ajustar os parâmetros de detecção de repetições conforme as características da execução analisada. No início do desenvolvimento, essa etapa dependia mais de parâmetros fixos definidos para o movimento. Com a evolução do sistema, foi implementada a segmentação configurável por sessão, permitindo ajustar os parâmetros de acordo com a execução real do paciente.

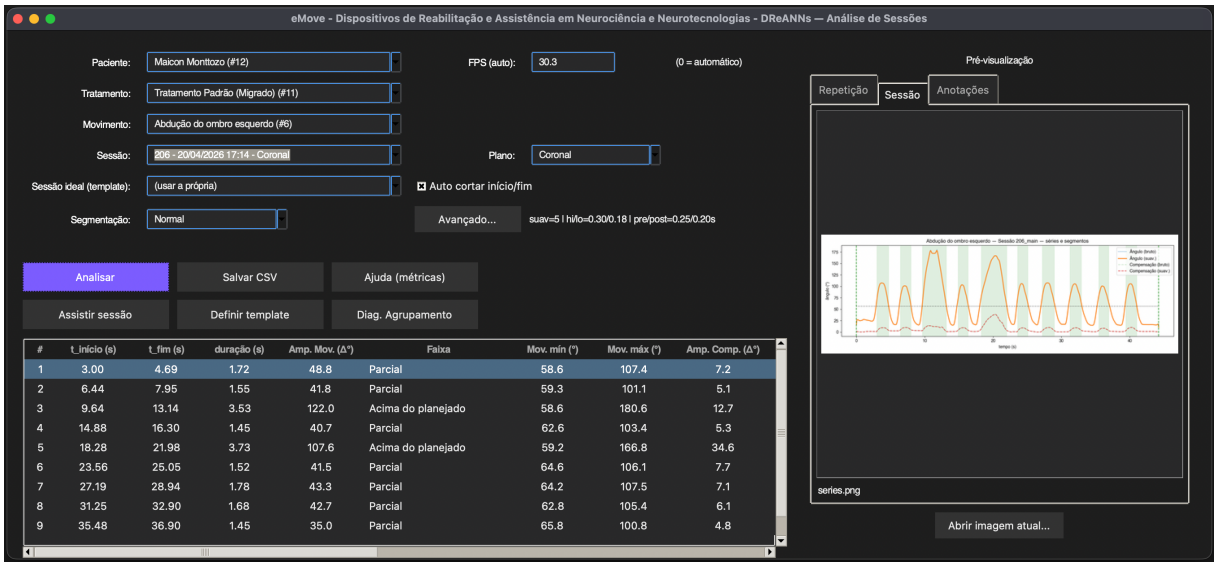
Essa mudança foi necessária porque cada paciente pode executar o mesmo movimento com ritmo, amplitude e regularidade diferentes. Um conjunto único de valores pode funcionar bem para um caso e não funcionar para outro. Por isso, a aplicação passou a permitir que a configuração da segmentação seja persistida junto à sessão.

Entre os parâmetros utilizados estão limiares, histerese, margens antes e depois da região ativa do movimento e ajustes relacionados à curva angular utilizada como base. Essa configuração permite maior controle sobre a divisão da sessão em repetições e reduz a necessidade de alterar regras globais para todos os pacientes.

A Figura 12 apresenta a principal interface de análise do eMove.

Nela são reunidos os elementos centrais do pipeline, incluindo a visualização das curvas angulares, as repetições detectadas, os parâmetros de segmentação e os atributos calculados para cada execução. Essa tela concentra grande parte do processo de revisão realizado pelos profissionais da saúde, permitindo validar a segmentação e analisar o comportamento individual das repetições.

Figura 12 – Interface de análise de sessões no eMove



Fonte: Autor

Com a segmentação, o sistema passa a analisar cada repetição separadamente. Isso permite identificar variações dentro da própria sessão, como repetições mais rápidas, mais lentas, com menor amplitude ou com maior compensação.

Após a segmentação, cada repetição recebe um conjunto de atributos calculados a partir das séries temporais. Entre os atributos extraídos estão a duração da repetição, a amplitude do movimento, a amplitude de compensação, medidas de similaridade temporal e informações derivadas da curva angular.

Quando aplicável, o DTW é utilizado para comparar a repetição com uma referência ou template, permitindo estimar a proximidade temporal entre execuções com durações diferentes.

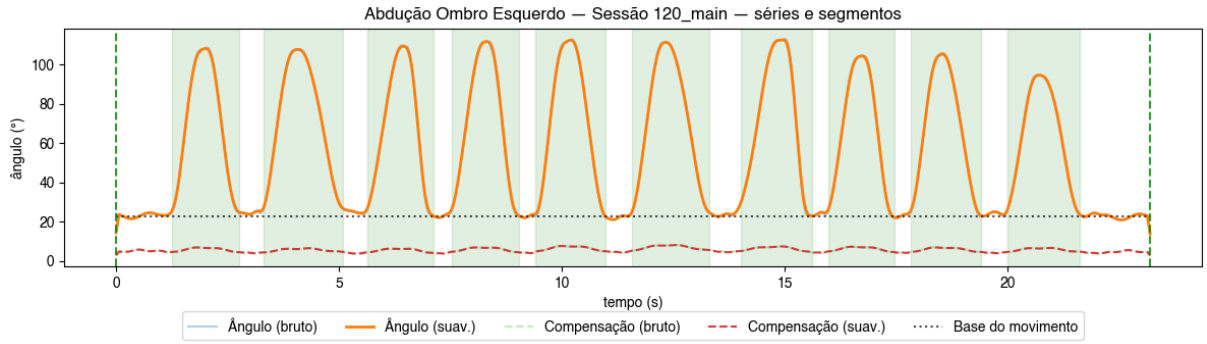
Os atributos por repetição também permitem que o sistema organize os dados em tabelas e gráficos. Isso facilita a análise dos profissionais da saúde, pois cada repetição passa a ter informações próprias, e não apenas um valor médio da sessão inteira.

A persistência desses atributos permite revisar classificações, refazer agrupamentos, treinar modelos supervisionados e gerar relatórios com base nos mesmos dados processados.

A segmentação produz uma representação da sessão em unidades individuais de movimento. A Figura 13 apresenta um exemplo de sessão após a detecção automática das repetições.

Observa-se que cada repetição passa a possuir início, fim e atributos próprios, permitindo análises mais detalhadas do que aquelas obtidas apenas pela observação da sessão completa.

Figura 13 – Gráfico de uma sessão segmentada em repetições



Fonte: Autor

6.6 Classificação, Curadoria e Templates de Referência

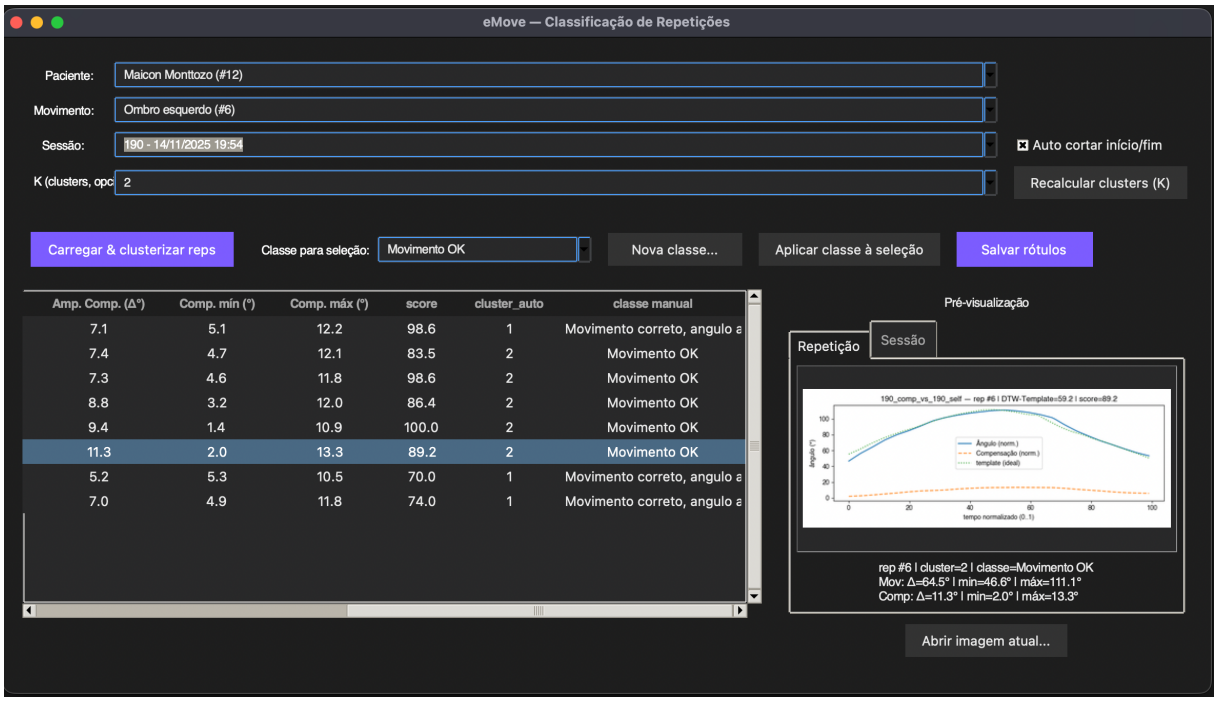
A classificação por faixas foi implementada para permitir uma leitura mais objetiva de determinados atributos, principalmente aqueles relacionados à amplitude do movimento. Para cada movimento, podem ser definidas faixas de classificação que representam intervalos interpretáveis pelos profissionais da saúde.

Essa abordagem permite classificar cada repetição de acordo com os valores obtidos, sem depender apenas de uma decisão automática complexa. Por exemplo, uma repetição pode ser enquadrada em determinada faixa de amplitude ou desempenho, de acordo com limites previamente definidos para aquele movimento.

Além da classificação automática por faixa, o sistema mantém espaço para curadoria manual. Os profissionais da saúde podem revisar a repetição, ajustar a classe atribuída e registrar observações. Essa curadoria é importante porque nem toda variação do movimento pode ser interpretada apenas por uma regra numérica.

A Figura 14 apresenta a interface utilizada para classificação das repetições.

Figura 14 – Interface de classificação das repetições da sessão



Fonte: Autor

Além dos atributos calculados automaticamente, o sistema permite que o profissional revise e ajuste as classes atribuídas. Essa possibilidade é importante porque a interpretação funcional do movimento nem sempre pode ser reduzida a uma única regra computacional.

Essa separação entre classificação automática e curadoria manual ajuda a manter os profissionais da saúde no centro do processo. O sistema sugere e organiza informações, mas a interpretação final continua dependendo da avaliação especializada.

A comparação entre execuções pode utilizar referências internas ou templates definidos no sistema. No fluxo inicial, a referência era obtida a partir da própria sessão analisada, por exemplo, escolhendo uma repetição mais representativa do conjunto. Essa abordagem permitia comparar as demais repetições com um padrão interno da sessão.

Com a evolução do eMove, foram incorporados templates de referência mais controlados. Esses templates podem ser associados ao paciente, tratamento, movimento e plano de gravação, permitindo comparações mais coerentes com o contexto de acompanhamento.

O uso de uma referência de movimento é importante porque evita depender sempre de um padrão universal. Em reabilitação, nem sempre existe um movimento ideal único que sirva para todos os pacientes. Por isso, uma referência contextualizada pode representar melhor o estágio atual do paciente ou o objetivo do tratamento.

Quando existe um template manual definido, ele pode ter prioridade sobre referências automáticas. Essa estratégia permite que o profissional selecione uma execução considerada

adequada para comparação, mantendo maior controle sobre o critério utilizado na análise.

6.7 Agrupamento Automático e Classificação Supervisionada

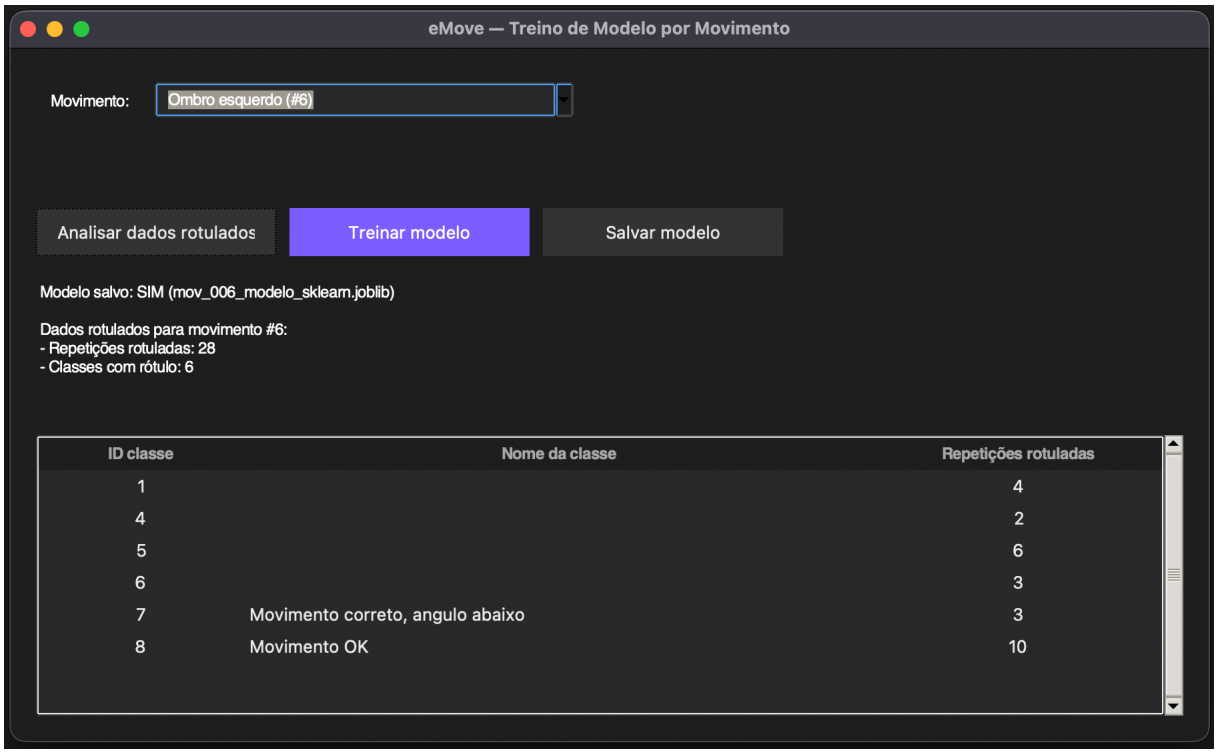
O agrupamento automático foi implementado para organizar repetições com características semelhantes. Essa etapa tem como objetivo apoiar o profissional na identificação de padrões, e não substituir sua interpretação.

O Agrupamento Hierárquico Baseado em Densidade para Aplicações com Ruído (*Hierarchical Density-Based Spatial Clustering of Applications with Noise*) (HDBSCAN) (CAMPELLO; MOULAVI; SANDER, 2013), implementado por meio da classe `sklearn.cluster.HDBSCAN` da biblioteca `scikit-learn` (PEDREGOSA et al., 2011), foi incorporado ao pipeline por permitir identificar agrupamentos de forma mais flexível e tratar alguns pontos como ruído quando não pertencem claramente a nenhum grupo. Essa característica é adequada ao contexto do eMove, no qual as execuções podem variar entre pacientes, sessões e movimentos.

Os grupos descobertos podem receber nomes interpretativos e ser validados manualmente. Essa etapa aproxima o agrupamento automático da leitura profissional, permitindo que padrões computacionais sejam associados a termos compreensíveis na prática clínica ou ambulatorial.

Além do agrupamento, o eMove implementa classificação supervisionada com base em atributos tabulares extraídos das repetições. Esses atributos incluem medidas como amplitude do movimento, compensação, duração, medidas de similaridade e classificações por faixa. A Figura 15 apresenta a interface utilizada para treinamento dos modelos supervisionados.

Figura 15 – Interface de treinamento do modelo de movimento



Fonte: Autor

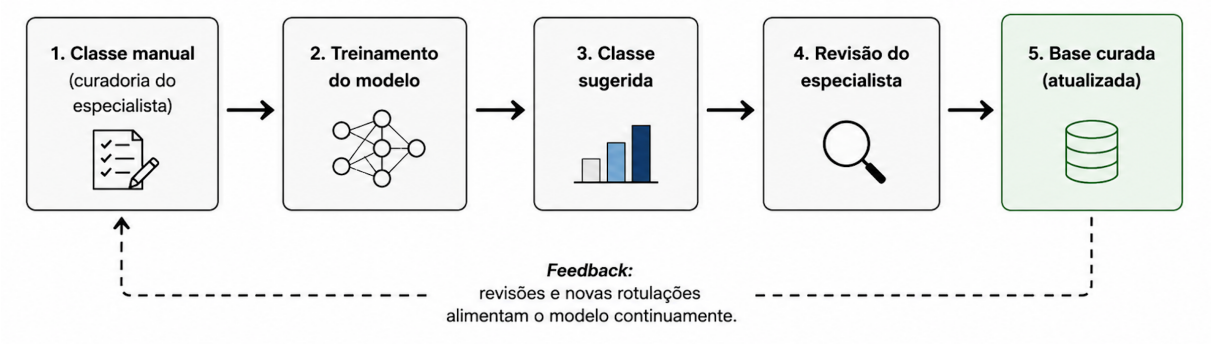
Os modelos são construídos a partir dos atributos extraídos das repetições e das classes previamente validadas pelos profissionais da saúde. Dessa forma, o processo de treinamento utiliza conhecimento especializado previamente curado durante o uso do sistema.

A classificação supervisionada utiliza como base as classes validadas ou ajustadas pelos profissionais da saúde. Assim, a classe manual permanece como referência principal, enquanto a classe sugerida pelo modelo funciona como apoio à análise.

Essa separação evita que o sistema seja apresentado como responsável pela decisão final. O objetivo é fornecer uma sugestão baseada nos dados históricos e nos atributos extraídos, mantendo a possibilidade de revisão e correção pelo especialista.

A estratégia adotada no eMove procura diferenciar claramente a classificação automática da decisão especializada. A Figura 16 resume esse fluxo.

Figura 16 – Fluxo de classificação supervisionada com curadoria especializada no eMove



Fonte: Autor

Inicialmente, as classes validadas pelos profissionais são utilizadas para treinamento do modelo supervisionado. Em seguida, o modelo pode sugerir classes para novas repetições. Essas sugestões são novamente revisadas pelos especialistas e passam a compor a base curada utilizada em treinamentos futuros.

Esse ciclo busca transformar a IA em um mecanismo de apoio à análise, e não em um substituto da avaliação profissional.

6.8 Relatórios, Privacidade e Adequação à LGPD

A geração de relatórios foi incorporada ao eMove para organizar os resultados produzidos durante a análise dos movimentos. Os relatórios podem reunir informações do paciente, tratamento, movimento analisado, sessões consideradas, métricas extraídas, classificações, gráficos e observações registradas pelos profissionais da saúde. Dessa forma, os resultados computacionais passam a ser apresentados em uma síntese mais adequada ao acompanhamento da evolução funcional e à comunicação entre profissionais.

As informações exibidas nos relatórios são derivadas diretamente dos dados processados e persistidos pela aplicação, mantendo vínculo com os parâmetros, atributos e classificações utilizados durante a análise. Essa organização também contribui para a rastreabilidade dos resultados, permitindo compreender como determinada análise foi produzida e revisada ao longo do acompanhamento.

Por lidar com informações relacionadas à saúde, a implementação incorpora mecanismos voltados à privacidade e à proteção dos dados. Entre eles estão autenticação de usuários, controle de acesso, organização multiempresa, compartilhamento controlado de pacientes e recursos para ocultação de informações identificáveis quando necessário. Essas medidas buscam reduzir a exposição indevida dos dados durante o uso clínico, ambulatorial ou em pesquisa aplicada.

A adequação à Lei Geral de Proteção de Dados (LGPD) é tratada como uma diretriz de projeto, orientando a adoção de mecanismos de proteção, controle de acesso e minimização da

exposição de dados pessoais. Embora a aplicação ainda possa evoluir em aspectos relacionados à auditoria, consentimento e políticas formais de retenção, os recursos implementados já demonstram uma preocupação com privacidade e segurança desde a concepção da solução.

A Figura 17 apresenta um exemplo de relatório exportado com ocultação de dados identificáveis, recurso desenvolvido para apoiar atividades de pesquisa, compartilhamento acadêmico e discussão de casos clínicos com menor exposição de informações pessoais.

Figura 17 – Relatório exportado com dados anonimizados



Laboratório Padrão 11/06/2026

Relatório de Evolução Funcional

Paciente: Paciente anonimizado Terapeuta: Não exibido

Lesão	Oculto
Intervenção Cirúrgica	Oculto
Médico Cirurgião	Não exibido

Descrição: Oculta

Reabilitação	Oculta
Registro	Registro anonimizado
Variável	Amplitude de Movimento (ADM)
Unidade	Graus (°)
Posição do Paciente / Plano	Plano Coronal

Tratamento: Operação ombro

Fonte: Autor

6.9 Atualização e Manutenção da Aplicação

A aplicação também recebeu mecanismos voltados à atualização e manutenção. Esse recurso permite distribuir novas versões do eMove, aplicar correções e manter o sistema atualizado de forma mais controlada.

O atualizador automático foi implementado para verificar a existência de novas versões e auxiliar no processo de substituição da aplicação. Em alguns cenários, a atualização pode ser opcional; em outros, pode ser necessária para garantir compatibilidade ou correções importantes.

Embora esse recurso não faça parte diretamente do algoritmo de análise de movimento, ele contribui para a viabilidade de uso do sistema em ambientes reais. Sistemas aplicados à saúde e pesquisa precisam ser mantidos de forma consistente, principalmente quando há evolução de modelos, ajustes de banco de dados, correções de interface ou melhorias de segurança.

A manutenção da aplicação também envolve o versionamento da estrutura de dados, a organização dos arquivos gerados e a compatibilidade com novas funcionalidades. Esses cuidados ajudam a preservar os dados existentes e reduzem riscos durante a evolução do software.

6.10 Considerações Finais

Este capítulo apresentou os principais recursos implementados no eMove e mostrou como a arquitetura descrita anteriormente foi transformada em uma aplicação funcional. Foram descritos o modelo de dados, o controle de acesso, a organização multiempresa, o compartilhamento de pacientes, a aquisição por câmera, a importação de vídeo, o processamento dos dados de movimento, a segmentação por sessão e a extração de atributos por repetição.

Também foram apresentadas as etapas de classificação por faixas, curadoria das repetições, uso de templates de referência, agrupamento automático, classificação supervisionada com atributos tabulares e geração de relatórios. Essas funcionalidades foram implementadas com o objetivo de apoiar o acompanhamento de movimentos em reabilitação física e neurofuncional, mantendo os profissionais da saúde no centro da interpretação.

Por fim, foram discutidos os recursos relacionados à privacidade, segurança, adequação à LGPD, rastreabilidade, atualização e manutenção da aplicação. No capítulo seguinte, são apresentados e discutidos os resultados computacionais obtidos a partir da consolidação desse pipeline e dos recursos implementados.

7 Resultados Computacionais e Discussão

7.1 Consolidação do Pipeline de Análise

Este capítulo apresenta os resultados computacionais obtidos com a consolidação do pipeline de análise do eMove. Diferentemente de uma validação clínica ampla, que ainda depende da ampliação da base para diferentes movimentos, perfis de participantes e da avaliação sistemática por profissionais da saúde (especialistas em Cinesiologia), os resultados discutidos nesta etapa concentram-se na avaliação computacional da solução desenvolvida e nas decisões de projeto consolidadas ao longo do trabalho.

A principal entrega computacional foi a consolidação de um pipeline capaz de transformar vídeos de movimento em informações estruturadas para apoio à análise funcional. O pipeline integra as etapas de captura ou importação do vídeo, extração de pose, cálculo de ângulos articulares, segmentação em repetições, extração de atributos, agrupamento automático, classificação supervisionada e geração de relatórios. Além da implementação dessas etapas, foi realizado um experimento computacional de prova de conceito utilizando uma base de dados gerada a partir de 40 integrantes do grupo de pesquisa, totalizando 160 sessões e 1.600 repetições do movimento de abdução do ombro esquerdo no plano coronal, permitindo analisar o comportamento dos módulos de agrupamento e classificação supervisionada.

Com essa estrutura, a análise deixa de depender apenas da observação visual da sessão completa. Cada repetição passa a ser tratada como uma unidade própria, com dados associados à duração, amplitude, compensação, similaridade temporal e classificação. Essa representação permite identificar diferenças entre execuções de uma mesma sessão, acompanhar a evolução entre sessões e fornecer informações estruturadas para os módulos de agrupamento, classificação supervisionada e geração de relatórios.

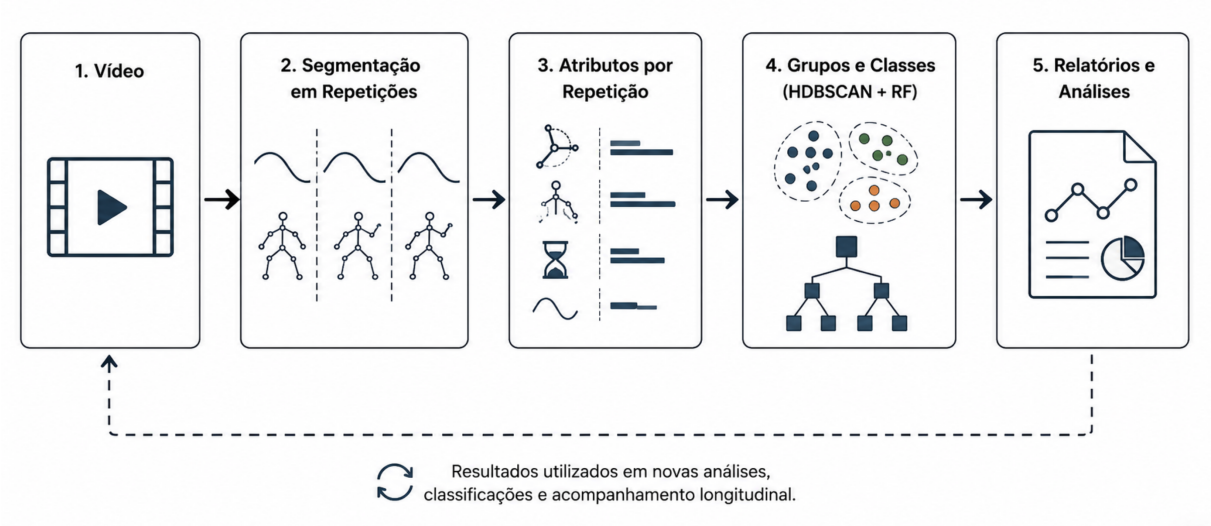
Outro aspecto importante é que o pipeline foi desenvolvido para funcionar com dados produzidos durante o próprio uso da aplicação. Assim, o sistema não depende de uma base externa universal para definir um movimento ideal. A curadoria dos profissionais da saúde e os dados coletados nas sessões constituem a base para o agrupamento, o treinamento supervisionado e o acompanhamento da evolução funcional.

Essa característica é particularmente relevante para a reabilitação física e neurofuncional, pois pacientes podem apresentar padrões motores distintos, ritmos diferentes e limitações específicas. Dessa forma, o pipeline foi estruturado para apoiar um acompanhamento individualizado, sem assumir que todos os pacientes devam ser comparados a um único padrão fixo.

A Figura 18 apresenta uma visão consolidada do pipeline de processamento e análise adotado no eMove, desde a captura ou importação do vídeo até a geração dos resultados utilizados

no acompanhamento do paciente.

Figura 18 – Fluxo consolidado de processamento e análise adotado no eMove



Fonte: Autor

O fluxo parte da captura ou importação do vídeo, passa pela segmentação em repetições, extração de atributos, agrupamento, classificação supervisionada e culmina na geração de relatórios e análises para acompanhamento longitudinal.

7.2 Segmentação, Atributos e Representação das Repetições

A segmentação das sessões em repetições constitui uma das etapas centrais do pipeline desenvolvido no eMove. Sua principal contribuição foi permitir que cada execução do movimento passasse a ser representada individualmente, tornando possível extrair atributos específicos de cada repetição e utilizá-los nas etapas posteriores de análise.

No eMove, a identificação das repetições é realizada a partir da curva angular do movimento, utilizando parâmetros configuráveis, como limiares, histerese e margens de segmentação. A possibilidade de configurar esses parâmetros por sessão tornou o processo mais flexível, permitindo sua adaptação às características de diferentes movimentos, participantes e condições de aquisição.

Após a segmentação, cada repetição passa a ser representada por um conjunto de atributos, incluindo duração, amplitude do movimento, amplitude de compensação, classificação por faixa e medidas de similaridade temporal. Quando aplicável, também são utilizadas distâncias baseadas em DTW, permitindo comparar execuções com durações distintas.

A adoção dessa representação por atributos tabulares representou uma evolução importante do pipeline. Em vez de utilizar apenas a onda reamostrada, a solução passou a trabalhar com informações mais interpretáveis, aproximando os resultados da linguagem utilizada pelos

profissionais da saúde. Além disso, essa representação passou a servir como entrada tanto para o agrupamento automático quanto para a classificação supervisionada implementada no eMove.

Outro resultado obtido foi a persistência dos atributos extraídos. Ao armazenar os valores calculados para cada repetição, o sistema permite revisar análises, reproduzir resultados, comparar sessões e gerar relatórios utilizando exatamente os mesmos dados processados, favorecendo a rastreabilidade das análises realizadas.

A Tabela 12 apresenta um exemplo de repetições identificadas em uma sessão analisada pelo eMove. Nela é possível observar parte dos atributos calculados automaticamente para cada repetição, incluindo duração, amplitude do movimento, amplitude de compensação e medidas de similaridade temporal.

Tabela 12 – Exemplo de atributos extraídos das repetições de uma sessão

Rep.	Duração (s)	Amp. Mov. (°)	Amp. Comp. (°)	DTW	Faixa
1	1,62	125,2	1,8	131,5	3º Estágio
2	1,55	122,1	1,6	0,0	3º Estágio
3	1,55	121,7	1,6	103,5	3º Estágio
4	1,49	123,0	1,7	93,3	3º Estágio
5	1,52	130,6	1,6	229,6	3º Estágio

Fonte: Autor

Observa-se que, mesmo dentro de uma única sessão, existem pequenas variações entre as repetições em termos de duração, amplitude e similaridade temporal. Essas diferenças reforçam a importância de tratar cada repetição como uma unidade individual de análise, permitindo identificar padrões que poderiam permanecer ocultos caso apenas estatísticas agregadas da sessão fossem consideradas.

Embora os valores apresentados na Tabela 12 pertençam a uma única sessão, eles ilustram como o movimento passa a ser representado por atributos estruturados. Essa representação constitui a base utilizada nas etapas de agrupamento automático, classificação supervisionada e geração dos relatórios apresentados nas seções seguintes.

7.3 Classificação das Repetições e Curadoria Especializada

A classificação das repetições foi estruturada para manter os profissionais da saúde no centro do processo. O sistema pode sugerir classificações, organizar faixas e apresentar agrupamentos, mas a curadoria especializada continua sendo necessária para validar, ajustar ou complementar os resultados.

Uma das estratégias implementadas foi a classificação por faixas. Essa classificação permite associar valores de amplitude ou outros atributos a intervalos previamente definidos

para cada movimento. Com isso, cada repetição pode ser enquadrada em uma faixa interpretável, facilitando a leitura da execução.

Essa abordagem ajuda principalmente em situações nas quais uma classificação puramente automática ainda não é suficiente. Em vez de depender apenas de uma decisão do modelo, o sistema apresenta uma primeira organização dos dados, que pode ser revisada pelos profissionais da saúde.

A classificação manual também é importante para formação do conjunto supervisionado. Quando os profissionais atribuem ou corrigem uma classe, essa informação passa a compor a base para treinamento futuro. Dessa forma, o sistema aprende a partir de exemplos validados no próprio contexto de uso.

Outro ponto considerado foi a proteção dos rótulos manuais. Como a segmentação pode ser ajustada em novas análises, o sistema precisa evitar que classificações manuais sejam reaproveitadas de forma indevida quando a quantidade ou os limites das repetições mudam. Essa preocupação ajuda a preservar a coerência dos dados supervisionados.

No conjunto analisado neste capítulo, a curadoria manual também foi utilizada para verificar a coerência dos agrupamentos obtidos e para formar a base supervisionada inicial. Essa base foi posteriormente utilizada na avaliação do modelo supervisionado, apresentada nas próximas seções.

7.4 Agrupamento Automático e Interpretação dos Padrões

O agrupamento automático foi utilizado como forma de organizar repetições com características semelhantes. O objetivo não é substituir a interpretação dos profissionais da saúde, mas reduzir o esforço de análise e ajudar na identificação de padrões recorrentes.

Em uma etapa inicial do desenvolvimento, foi testada uma abordagem baseada em k-medoids (KAUFMAN; ROUSSEEUW, 1990). A escolha inicial desse método ocorreu porque ele trabalha com representantes reais do conjunto, chamados medoides, e pode ser aplicado em cenários nos quais se utilizam matrizes de distância, como aquelas derivadas do DTW. Essa característica tornava o método adequado para uma primeira organização das repetições por similaridade.

No entanto, durante a evolução do projeto, observou-se que os dados reais de movimento não necessariamente formavam grupos bem definidos, com separação clara ou tamanhos semelhantes. Em algumas sessões, havia execuções intermediárias, repetições com comportamento raro e padrões que não se encaixavam de forma adequada em uma quantidade fixa de grupos.

O HDBSCAN (CAMPELLO; MOULAVI; SANDER, 2013), implementado por meio da classe `sklearn.cluster.HDBSCAN` da biblioteca `scikit-learn` (PEDREGOSA et al., 2011), foi adotado na etapa de agrupamento por não exigir a definição prévia do número de grupos,

lidar adequadamente com agrupamentos de diferentes densidades e identificar repetições que não pertencem claramente a nenhum padrão recorrente, classificando-as como ruído. Essa substituição tornou o agrupamento mais coerente com a realidade dos dados do eMove. Em vez de forçar toda repetição a pertencer a um grupo, o sistema pode indicar que alguns padrões são menos frequentes ou não se encaixam bem nas estruturas encontradas.

Os grupos descobertos podem receber nomes interpretativos e ser avaliados pelos profissionais da saúde. Essa etapa é importante porque transforma o resultado do agrupamento em algo mais próximo da prática clínica ou ambulatorial. Assim, o agrupamento funciona como apoio à interpretação e à curadoria, e não como diagnóstico automático.

A definição da estratégia final de agrupamento ocorreu de forma incremental ao longo do desenvolvimento do eMove. Diferentes combinações de atributos e representações do movimento foram avaliadas com o objetivo de encontrar uma configuração que apresentasse boa separação dos grupos e, ao mesmo tempo, mantivesse interpretabilidade para os profissionais da saúde.

Para essa prova de conceito, foi utilizada a base de dados do grupo de estudo, detalhada na Tabela 13. Diferentemente de uma análise individual por sessão, todas as repetições foram agrupadas conjuntamente, permitindo observar padrões recorrentes em uma base mais ampla.

Os experimentos iniciais utilizaram representações baseadas principalmente nas curvas temporais do movimento e medidas derivadas do DTW. Embora essas abordagens permitissem identificar similaridades entre execuções, os agrupamentos produzidos apresentavam menor interpretabilidade clínica e frequentemente geravam maior dificuldade para nomear e caracterizar os grupos encontrados.

Posteriormente, foram realizados experimentos utilizando atributos clínicos explícitos extraídos de cada repetição, incluindo amplitude máxima do movimento, amplitude máxima de compensação e duração da execução. Essa estratégia produziu agrupamentos mais consistentes e mais facilmente interpretáveis.

A configuração final adotada utilizou o algoritmo HDBSCAN aplicado sobre os atributos amplitude, compensação e duração, resultando em dois grupos distintos e ausência de repetições classificadas como ruído na base analisada.

Tabela 13 – Resumo da base utilizada na avaliação dos agrupamentos

Métrica	Valor
Integrantes	40
Sessões	160
Repetições	1600
Movimento	Abdução Ombro Esquerdo
Plano	Coronal
Grupos identificados	2
Ruído identificado	0
Percentual de ruído	0,0%

Fonte: Autor

Para viabilizar a reprodução dos resultados apresentados, a Tabela 14 detalha os hiperparâmetros do HDBSCAN utilizados nesta avaliação, incluindo os atributos considerados e os pesos aplicados a cada um deles antes do agrupamento.

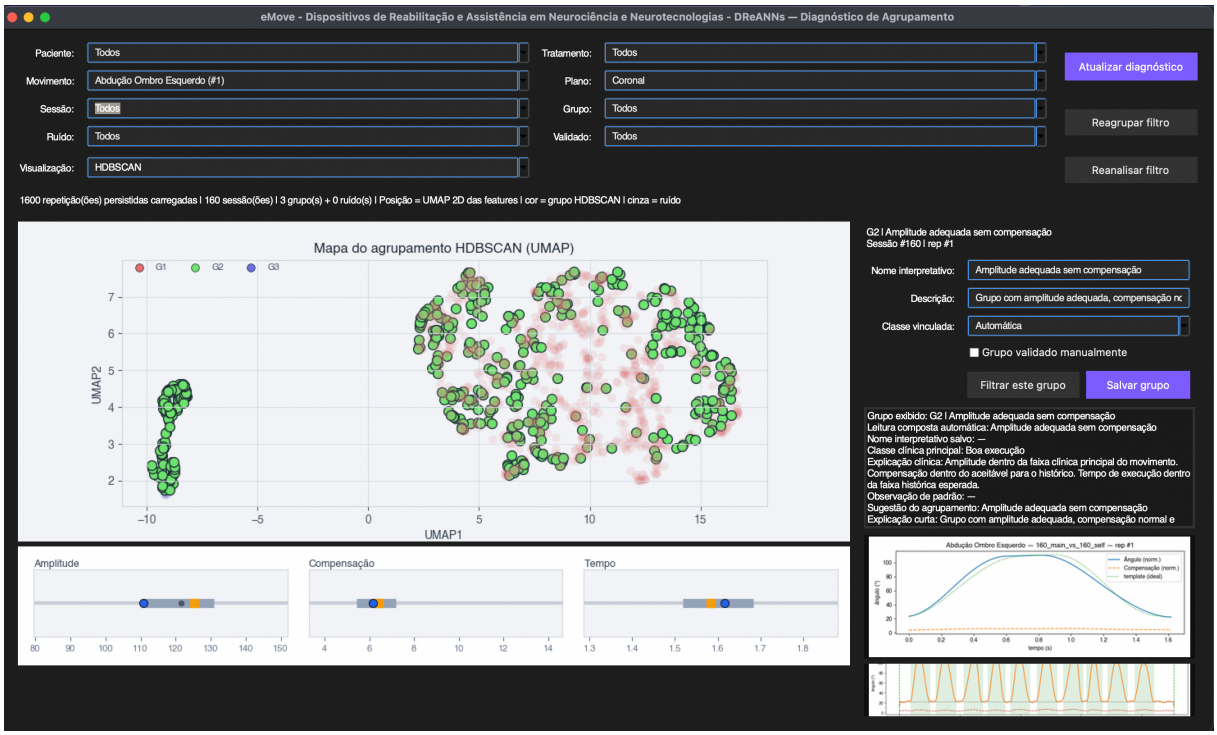
Tabela 14 – Hiperparâmetros do HDBSCAN utilizados na avaliação dos agrupamentos

Parâmetro	Valor
min_cluster_size	20 (calculado dinamicamente: $\min(20, \max(8, \text{round}(n \times 0.12)))$, com $n = 1600$)
min_samples	5
metric	manhattan
cluster_selection_method	eom
cluster_selection_epsilon	0,20
allow_single_cluster	Verdadeiro
Atributos utilizados e pesos	amplitude do movimento (2,40), amplitude de compensação (2,60), duração (1,20), normalizados por `RobustScaler`
Implementação	`sklearn.cluster.HDBSCAN` (PEDREGOSA et al., 2011)

Fonte: Autor

A Figura 19 apresenta um exemplo de agrupamento obtido pelo eMove para o movimento de abdução do ombro esquerdo. A visualização utiliza projeção UMAP (MCINNES; HEALY; MELVILLE, 2018) para representar as repetições em duas dimensões, enquanto as cores indicam os grupos identificados pelo HDBSCAN. Além da distribuição dos agrupamentos, o sistema permite visualizar métricas resumidas e exemplos de repetições pertencentes ao grupo selecionado, auxiliando na interpretação dos padrões encontrados.

Figura 19 – Visualização dos agrupamentos identificados pelo HDBSCAN utilizando projeção UMAP



Fonte: Autor

A Figura 19 apresenta a projeção bidimensional dos agrupamentos encontrados. Embora a projeção UMAP reduza a dimensionalidade dos dados para fins de visualização, é possível observar regiões com maior concentração de repetições e a separação entre os grupos identificados pelo HDBSCAN. Essa visualização é usada como apoio à análise, enquanto a interpretação dos grupos é realizada a partir dos atributos originais.

Tabela 15 – Caracterização dos grupos identificados pelo HDBSCAN

Grupo	Classe validada	Repetições	Sessões	Pacientes	% Total
G1	Boa execução	1430	143	36	89,4
G2	Amplitude adequada com compensação	170	17	5	10,6

Fonte: Autor

Observa-se que a maior parte das repetições foi agrupada no Grupo 1, posteriormente validado como “Boa execução”, representando 89,4% da base analisada. O Grupo 2 concentrou repetições classificadas como “Amplitude adequada com compensação”, correspondendo a 10,6% das execuções. A ausência de repetições classificadas como ruído sugere que os atributos selecionados foram suficientes para representar os padrões observados na base analisada.

A coluna “Pacientes” da Tabela 15 representa o número de pacientes únicos com pelo menos uma repetição em cada grupo. Como o agrupamento ocorre no nível da repetição, um mesmo paciente pode contribuir repetições para mais de um grupo; por esse motivo, a soma das

contagens por grupo não corresponde diretamente ao total de 40 participantes da base. Nesta avaliação, um participante apresentou repetições em ambos os grupos, de modo que a união dos dois conjuntos totaliza os 40 participantes.

Após a execução do agrupamento, todas as 1.600 repetições foram revisadas manualmente pelo autor, permitindo verificar a coerência dos agrupamentos encontrados em relação às características observadas nas execuções. Essa prova de conceito teve caráter exploratório e computacional, com o objetivo de avaliar se os grupos gerados pelo algoritmo apresentavam padrões consistentes e passíveis de interpretação.

Embora os resultados indiquem que os agrupamentos encontrados são coerentes com os atributos utilizados durante a análise e apresentem boa capacidade de representação dos padrões observados na base avaliada, este estudo não constitui uma validação clínica formal. Os resultados obtidos demonstram a viabilidade computacional da abordagem proposta e indicam que o eMove está apto para utilização em estudos e avaliações experimentais, permanecendo como etapa futura a validação dos agrupamentos por profissionais da saúde (especialistas em Cinesiologia) em diferentes contextos clínicos.

Tabela 16 – Características médias dos grupos identificados

Grupo	Amplitude Média (°)	Compensação Média (°)	Duração Média (s)
Boa execução	97,17	2,20	1,593
Amplitude adequada com compensação	98,23	4,20	1,587

Fonte: Autor

A Tabela 16 apresenta as características médias de cada grupo. A principal diferença entre os grupos está relacionada à amplitude de compensação. Enquanto os valores de amplitude do movimento e duração permaneceram próximos entre os grupos, o grupo classificado como "Amplitude adequada com compensação" apresentou compensação média aproximadamente duas vezes maior que o grupo classificado como "Boa execução". Esse resultado sugere que a compensação foi a variável com maior influência na separação dos padrões identificados pelo algoritmo.

7.5 Classificação Supervisionada com Atributos Tabulares

A classificação supervisionada foi incorporada ao pipeline com o objetivo de sugerir classes para novas repetições a partir de exemplos previamente classificados manualmente. Para isso, o eMove mantém separadas a classe manual, atribuída durante a avaliação das repetições, e a classe sugerida pelo modelo supervisionado. Essa estratégia preserva a decisão dos profissionais da saúde e permite que as sugestões do sistema sejam revisadas antes de integrarem a base de conhecimento da aplicação.

Ao longo do desenvolvimento, a representação das repetições evoluiu de séries temporais reamostradas para um conjunto de atributos tabulares, incluindo amplitude do movimento, amplitude de compensação, duração, medidas de similaridade temporal e classificação por faixa. Essa mudança tornou mais adequada a utilização de modelos capazes de explorar relações entre múltiplos atributos.

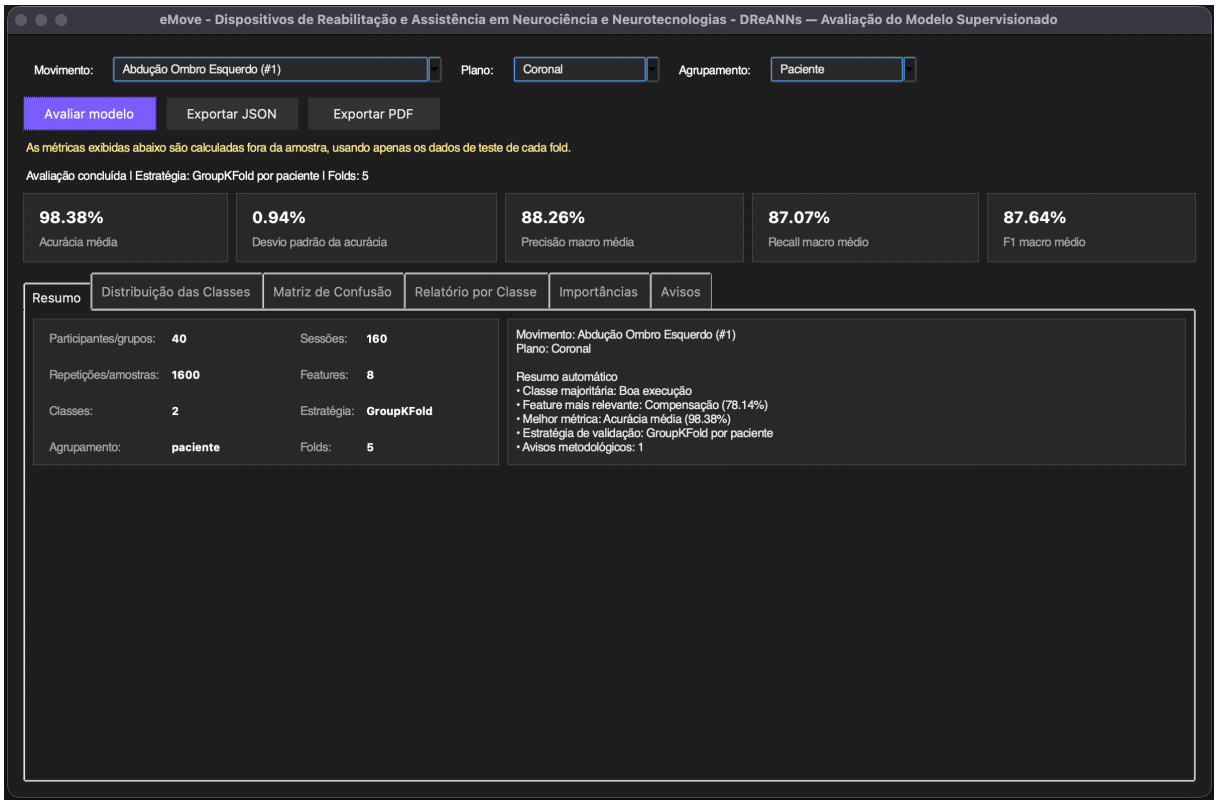
Inicialmente, foram avaliadas alternativas de classificação, incluindo o k-NN. Com a adoção da representação tabular, optou-se pela utilização do RF (`RandomForestClassifier` do `scikit-learn` (PEDREGOSA et al., 2011)), por apresentar melhor adequação à combinação dos atributos utilizados pelo pipeline e maior capacidade de adaptação à evolução da base supervisionada.

Durante a avaliação dos agrupamentos, as 1.600 repetições da base analisada foram classificadas manualmente, resultando principalmente nas classes "Boa execução" e "Amplitude adequada com compensação". Esses rótulos passaram a constituir a base supervisionada utilizada pelo módulo de treinamento e avaliação do eMove.

A avaliação supervisionada foi realizada utilizando o movimento de abdução do ombro esquerdo no plano coronal, com os dados do mesmo grupo de estudo apresentado na Tabela 13. Para reduzir o risco de superestimação do desempenho, foi empregada validação cruzada do tipo *GroupKFold*, considerando o integrante como unidade de agrupamento. Dessa forma, as repetições de um mesmo integrante não aparecem simultaneamente nos conjuntos de treinamento e teste em uma mesma iteração.

A avaliação foi realizada em cinco *folds*, sendo todas as métricas calculadas exclusivamente sobre os dados de teste de cada iteração. A Figura 20 apresenta a interface desenvolvida no eMove para reunir os resultados da avaliação supervisionada, incluindo métricas globais, distribuição das classes, matriz de confusão, relatório por classe, importância dos atributos e informações metodológicas.

Figura 20 – Interface de avaliação do modelo supervisionado no eMove



Fonte: Autor

Os resultados obtidos indicaram acurácia média de 98,38%, precisão macro média de 88,26%, *recall* macro médio de 87,07% e F1-score macro médio de 87,64%. O desvio padrão da acurácia foi de 0,94%, indicando comportamento estável entre os *folds* avaliados. Já as métricas macro (precisão, *recall* e F1) apresentaram desvio padrão bem mais alto entre os *folds* (19,93%, 18,62% e 19,27%, respectivamente), refletindo a instabilidade esperada quando a classe minoritária – concentrada em apenas 5 dos 40 integrantes – fica pouco representada ou ausente do conjunto de teste em algumas dobras do *GroupKFold*.

Tabela 17 – Métricas obtidas na avaliação supervisionada com Random Forest

Métrica	Valor
Acurácia média	98,38%
Desvio padrão da acurácia	0,94%
Precisão macro média	88,26%
Desvio padrão da precisão macro	19,93%
Recall macro médio	87,07%
Desvio padrão do recall macro	18,62%
F1-score macro médio	87,64%
Desvio padrão do F1-score macro	19,27%
Validação	GroupKFold por integrante
Número de folds	5

Fonte: Autor

Os hiperparâmetros do RF utilizados nesta avaliação são apresentados na Tabela 18.

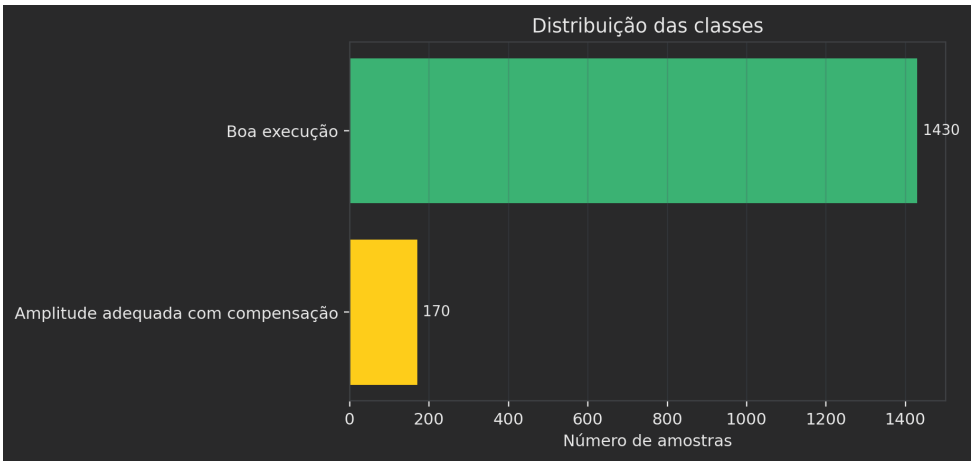
Tabela 18 – Hiperparâmetros do RandomForestClassifier utilizados na avaliação supervisionada

Parâmetro	Valor
n_estimators	300
max_depth	Sem limite (*None*)
min_samples_leaf	1
criterion	gini (padrão)
class_weight	balanced_subsample
random_state	42
Implementação	`sklearn.ensemble.RandomForestClassifier` (PEDREGOSA et al., 2011)

Fonte: Autor

A Figura 21 apresenta a distribuição das classes utilizadas na avaliação. Observa-se predominância da classe "Boa execução", com 1.430 repetições, enquanto a classe "Amplitude adequada com compensação" possui 170 repetições. Esse desbalanceamento deve ser considerado na interpretação das métricas, principalmente porque a acurácia tende a ser influenciada pela classe majoritária.

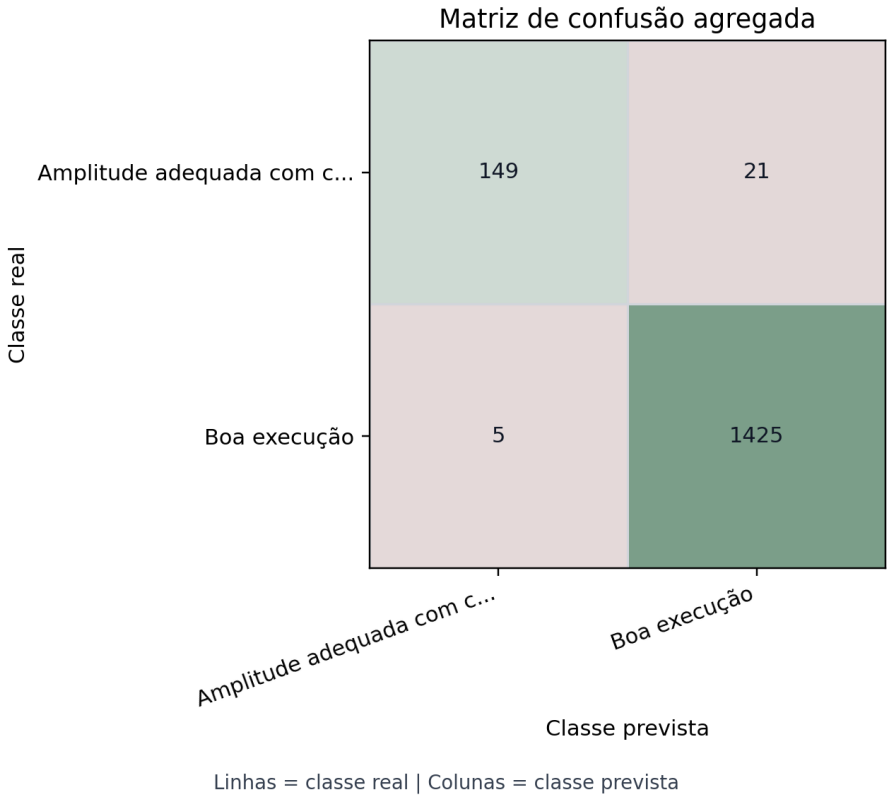
Figura 21 – Distribuição das classes utilizadas na avaliação supervisionada



Fonte: Autor

A matriz de confusão agregada, apresentada na Figura 22, mostra que a maior parte das repetições foi corretamente classificada. Das 170 repetições da classe "Amplitude adequada com compensação", 149 foram classificadas corretamente e 21 foram classificadas como "Boa execução". Já na classe "Boa execução", 1.425 das 1.430 repetições foram classificadas corretamente.

Figura 22 – Matriz de confusão agregada da validação supervisionada

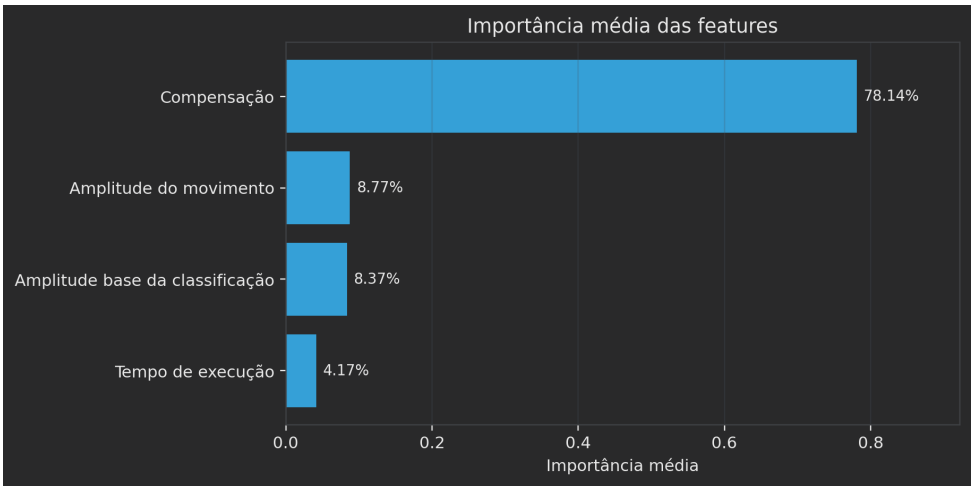


Fonte: Autor

O relatório por classe indicou F1-score de 91,98% para a classe “Amplitude adequada com compensação” e 99,10% para a classe “Boa execução”. Esse relatório, assim como a matriz de confusão agregada da Figura 22, é calculado uma única vez sobre as previsões de todos os *folds* combinadas (predições fora da amostra concatenadas), o que é diferente do cálculo da Tabela 17, cujas médias macro são obtidas calculando as métricas separadamente em cada *fold* e depois tirando a média simples entre eles. Por esse motivo, os valores de F1 por classe apresentados aqui não devem ser comparados diretamente com o F1-score macro médio da Tabela 17: ambos descrevem o mesmo modelo, mas a partir de agregações estatísticas diferentes. Esses resultados indicam que o modelo apresentou bom desempenho na base analisada, mesmo com a diferença de quantidade de amostras entre as classes.

Além da avaliação quantitativa, o eMove também calcula a importância média dos atributos utilizados pelo RF. Essa informação contribui para a interpretabilidade dos resultados, pois permite observar quais atributos exerceram maior influência na decisão do modelo.

Figura 23 – Importância média dos atributos calculada pelo Random Forest



Fonte: Autor

Na avaliação realizada, a amplitude de compensação foi o atributo de maior importância para o modelo, representando aproximadamente 78,14% da importância média calculada. Em seguida apareceram amplitude do movimento, com 8,77%, amplitude base da classificação, com 8,37%, e duração da execução, com 4,17%. Esse resultado reforça a relevância da compensação para distinguir os padrões observados na base analisada.

O modelo utilizou oito atributos de entrada: amplitude do movimento, amplitude de compensação, duração, o valor de amplitude associado à faixa de classificação e quatro variáveis binárias derivadas da codificação *one-hot* da faixa de classificação (ausência de faixa, faixa 2, faixa 3 e faixa não mapeada). A soma das oito importâncias médias totaliza exatamente 100%; a Figura 23 exibe apenas os atributos com importância média igual ou superior a 0,5%, motivo pelo qual os valores apresentados somam aproximadamente 99,45% – os cerca de 0,55% restantes correspondem às variáveis binárias de faixa com menor importância individual (0,28% e 0,26%). Nesta avaliação específica, medidas de similaridade temporal (DTW) não foram utilizadas como atributo de entrada do modelo, permanecendo como um recurso auxiliar do pipeline ainda não incorporado à classificação supervisionada.

É importante destacar que essa avaliação tem caráter computacional e está restrita ao movimento, plano e população analisados. Os resultados não devem ser generalizados para outros movimentos, perfis de pacientes ou contextos clínicos sem nova avaliação específica. Ainda assim, os valores obtidos demonstram que o fluxo supervisionado implementado no eMove é capaz de utilizar atributos tabulares extraídos das repetições para apoiar a classificação automática.

7.6 Relatórios, Interpretabilidade e Acompanhamento Longitudinal

A geração de relatórios foi consolidada como uma das principais saídas do pipeline. Os relatórios organizam dados processados pelo sistema e os apresentam de forma mais adequada para acompanhamento do tratamento.

Entre as informações que podem compor o relatório estão dados do paciente, tratamento, movimento analisado, sessões selecionadas, gráficos de melhoria, atributos por repetição, classificações e observações registradas pelos profissionais da saúde. Com isso, o relatório deixa de ser apenas uma saída visual e passa a funcionar como uma síntese do acompanhamento.

Esse recurso é importante porque o acompanhamento em reabilitação não ocorre apenas em uma sessão isolada. A melhoria do paciente precisa ser observada ao longo do tempo, considerando variações entre sessões, melhora de consistência, aumento de amplitude, redução de compensações ou maior regularidade na execução.

Os relatórios também ajudam na comunicação entre profissionais da saúde e, quando adequado, com o próprio paciente ou familiares. A saída gerada precisa ser compreensível, sem perder o vínculo com os dados computacionais que deram origem à análise.

Ao reunir métricas, gráficos e observações, o relatório fecha o ciclo do pipeline: o vídeo é transformado em dados, os dados são processados em atributos e classificações, e esses resultados são organizados em uma forma que pode apoiar o acompanhamento terapêutico.

Como parte da evolução do pipeline, também foi implementada a exportação dos resultados da avaliação supervisionada em formato estruturado. O sistema gera relatórios em PDF, arquivos JSON e imagens com os principais gráficos, facilitando a consulta posterior e a utilização desses resultados em análises e documentação.

A interpretabilidade foi tratada como uma diretriz do desenvolvimento do eMove. O sistema ainda não utiliza, nesta etapa, técnicas formais de XAI, como métodos específicos de explicação pós-hoc. Mesmo assim, algumas decisões foram tomadas para que os resultados sejam mais compreensíveis aos profissionais da saúde.

A primeira decisão foi trabalhar com atributos interpretáveis. Medidas como amplitude, duração, compensação, similaridade temporal e classificação por faixa são mais próximas da linguagem usada na análise do movimento do que saídas numéricas isoladas de um modelo.

A segunda decisão foi manter a curadoria profissional no processo. O sistema não apenas apresenta uma classe final, mas permite visualizar repetições, revisar agrupamentos, ajustar classes e registrar observações. Isso torna a análise mais transparente e reduz a dependência de uma decisão automática fechada.

A terceira decisão foi separar claramente os resultados calculados, as classes sugeridas e as classes manuais. Essa separação ajuda a entender o que foi produzido pelo sistema e o que foi validado pelos profissionais da saúde.

A avaliação supervisionada também contribuiu para a interpretabilidade da solução, pois permitiu observar a importância média dos atributos utilizados pelo modelo. O fato de a compensação ter sido a variável mais relevante no RF reforça a coerência entre os agrupamentos identificados, a curadoria realizada e a representação tabular adotada pelo pipeline.

Assim, a interpretabilidade no eMove é tratada como uma característica do pipeline e da forma de apresentação dos resultados. A adoção de técnicas formais de XAI permanece como possibilidade de melhoria futura, especialmente para explicar com mais detalhes a contribuição de cada atributo nas classificações sugeridas.

7.7 Limitações Atuais

Apesar dos avanços obtidos, o eMove ainda apresenta limitações. A principal delas é a necessidade de ampliar a base de dados rotulada para outros movimentos, planos de gravação, sessões e perfis de participantes. A classificação supervisionada depende da quantidade e da qualidade dos exemplos validados, e esse conjunto tende a crescer gradualmente com o uso do sistema.

Essa limitação é particularmente evidente na classe minoritária utilizada na avaliação supervisionada (Tabela 17), representada por apenas 5 dos 40 participantes. Para investigar a alta variabilidade observada nas métricas macro entre os *folds* de validação cruzada, foi testada uma reexecução da avaliação substituindo o `GroupKFold` por `StratifiedGroupKFold`, que busca preservar a proporção de classes entre as dobras. Os resultados obtidos foram muito próximos aos originais (precisão macro de 88,51% $\pm$ 20,05%, *recall* macro de 87,11% $\pm$ 18,64%, F1 macro de 87,78% $\pm$ 19,33%), mantendo a mesma dispersão elevada entre *folds*. Esse resultado indica que a instabilidade não decorre da ausência ocasional da classe minoritária em alguma dobra, mas da baixa diversidade de participantes que a representam: isolar qualquer um dos 5 participantes dessa classe para teste remove uma parcela substancial e específica do padrão de execução aprendido pelo modelo. Dessa forma, a ampliação do número de participantes com esse padrão de movimento é mais relevante do que ajustes na estratégia de validação cruzada para reduzir essa instabilidade.

Outra limitação está relacionada à ausência de validação clínica em larga escala. Os resultados apresentados neste capítulo demonstram a consolidação computacional do pipeline e a avaliação do modelo supervisionado em um cenário específico, utilizando dados provenientes de integrantes do grupo de pesquisa e um único movimento. Dessa forma, embora os resultados indiquem desempenho computacional satisfatório nesse contexto, ainda não é possível afirmar sua generalização para pacientes em reabilitação, outros movimentos ou diferentes condições clínicas. A ampliação dessa avaliação, envolvendo maior número de pacientes, movimentos e profissionais da saúde (especialistas em Cinesiologia), constitui uma etapa importante para trabalhos futuros.

A qualidade do vídeo também influencia o resultado. Iluminação inadequada, enquadramento ruim, oclusões e roupas que dificultam a identificação corporal podem afetar a extração de pose e, consequentemente, os ângulos e atributos calculados.

Também é necessário considerar que a interpretação dos resultados depende do contexto clínico ou funcional. As classificações sugeridas pelo sistema não devem ser utilizadas isoladamente para subsidiar diagnósticos ou decisões terapêuticas, devendo ser interpretadas em conjunto com a avaliação realizada pelos profissionais da saúde.

Por fim, a interpretabilidade formal ainda representa uma oportunidade de evolução do sistema. Embora o eMove já utilize atributos interpretáveis, apresente métricas de desempenho, calcule a importância dos atributos e mantenha a curadoria especializada como parte do processo, técnicas específicas de XAI ainda podem ser incorporadas para fornecer explicações mais detalhadas sobre as decisões produzidas pelos modelos supervisionados.

Outra limitação refere-se ao escopo atual dos experimentos realizados. Os resultados apresentados concentram-se em um único movimento do membro superior, avaliado em um plano específico. A ampliação para outros movimentos, articulações e protocolos de avaliação permitirá verificar a robustez do pipeline em diferentes cenários de reabilitação física e neurofuncional.

7.8 Considerações Finais

Este capítulo discutiu os principais resultados computacionais obtidos com a consolidação do pipeline do eMove. Foram apresentados os resultados relacionados à segmentação das sessões em repetições, extração de atributos, classificação por faixas, curadoria especializada, agrupamento automático, classificação supervisionada, relatórios, interpretabilidade e limitações atuais.

A evolução do pipeline mostrou a necessidade de ajustar os métodos computacionais ao tipo de dado produzido pelo sistema. Nesse sentido, a substituição do k-medoids por HDBSCAN no agrupamento e do k-NN por RF na classificação supervisionada representou uma adaptação importante às características reais das repetições e dos atributos tabulares.

Outro resultado importante foi a implementação da avaliação supervisionada integrada ao eMove. A utilização de validação cruzada *GroupKFold* por participante permitiu avaliar o modelo em dados não vistos durante o treinamento, reduzindo o risco de superestimação do desempenho. Na base analisada, o RF apresentou acurácia média de 98,38% e F1-score macro médio de 87,64%, com destaque para a amplitude de compensação como atributo mais relevante para a classificação.

Os resultados apresentados indicam que o eMove consolidou uma estrutura computacional capaz de transformar vídeos de movimento em dados organizados, analisáveis e úteis para acompanhamento em reabilitação física e neurofuncional. Ao mesmo tempo, a solução

ainda depende de validação clínica ampliada, expansão da base de dados e aprofundamento das estratégias de interpretabilidade.

No próximo capítulo, são apresentadas as considerações finais do trabalho, retomando os objetivos, as contribuições, as limitações e os trabalhos futuros.

8 Considerações Finais

8.1 Síntese do Trabalho

Este trabalho teve como objetivo apresentar a proposta e a implementação de uma solução computacional para apoiar a análise, a classificação e o acompanhamento de movimentos humanos em contextos de reabilitação física e neurofuncional. Para isso, foi conduzida uma revisão sistemática da literatura e, a partir das evidências encontradas, foi desenvolvido o eMove, uma aplicação voltada à análise de movimentos/protocolos por vídeo, extração de pose, cálculo de ângulos articulares, segmentação de sessões em repetições, extração de atributos e apoio à interpretação dos profissionais da saúde (especialistas em Cinesiologia).

A revisão sistemática permitiu mapear abordagens computacionais aplicadas à análise e classificação de movimentos humanos, considerando diferentes formas de captura, como sensores vestíveis, sinais de sEMG, câmeras e técnicas de visão computacional. Os estudos analisados também evidenciaram o uso de métodos de aprendizado de máquina e aprendizado profundo, além de limitações recorrentes relacionadas à disponibilidade de dados, variabilidade entre pacientes, necessidade de curadoria especializada e dificuldade de interpretação das saídas produzidas pelos modelos.

A partir desses achados, o eMove foi estruturado como uma solução aplicada, buscando aproximar técnicas computacionais da rotina de análise de movimentos em ambientes clínicos, ambulatoriais ou de pesquisa aplicada. O sistema não foi concebido como substituto da avaliação dos profissionais da saúde (especialistas em Cinesiologia), mas como um apoio para organizar dados, gerar medidas, destacar padrões e registrar a avaliação da evolução funcional ao longo do tempo.

Durante o desenvolvimento, o pipeline evoluiu de uma análise mais centrada na sessão para uma análise mais detalhada por repetição. Essa mudança permitiu representar cada execução do movimento por atributos próprios, como duração, amplitude, compensação, medidas de similaridade e classificações. Com isso, tornou-se possível comparar repetições dentro de uma mesma sessão e também acompanhar variações entre sessões de um mesmo tratamento.

Além da implementação e da avaliação computacional apresentadas, o eMove também foi disponibilizado para utilização em ambientes de pesquisa parceiros. Durante o desenvolvimento deste trabalho, a solução foi instalada e disponibilizada para avaliação no Laboratório de Interfaces e Visualização (LIV), da UNESP, e no Laboratório de Informática em Saúde e Inovação (LISI), da PUC-Campinas. Essa disponibilização amplia as possibilidades de coleta de dados, identificação de melhorias e futuras validações com profissionais da saúde em ambientes reais de uso.

8.2 Atendimento aos Objetivos

Em relação ao primeiro objetivo específico, foi conduzida uma revisão sistemática da literatura para mapear técnicas computacionais e métodos de IA aplicados à análise, classificação e acompanhamento de movimentos humanos em contextos de saúde e reabilitação. A revisão permitiu identificar modalidades de captura, tipos de dados, tecnologias utilizadas, abordagens de modelagem e lacunas relevantes para o desenvolvimento da solução.

O segundo objetivo específico consistia em projetar a arquitetura do eMove com base nas lacunas identificadas na literatura e nas necessidades de análise de movimentos em reabilitação física e neurofuncional. Esse objetivo foi atendido por meio da definição da arquitetura técnica, da visão funcional, do modelo de informação paciente–tratamento–movimento/protocolo–sessão–repetição e de um pipeline que integra aquisição ou importação de vídeo, extração de pose, cálculo angular, segmentação, extração de atributos, classificação, relatórios e rastreabilidade dos dados.

O terceiro objetivo específico estava relacionado à implementação de um pipeline para aquisição e importação de vídeos, extração de pose corporal, cálculo de ângulos articulares, segmentação de sessões em repetições e extração de atributos por repetição. Esse objetivo foi contemplado com a implementação dos módulos de captura, importação, processamento dos dados de movimento, segmentação configurável por sessão e persistência dos atributos extraídos.

O quarto objetivo específico previa o desenvolvimento de mecanismos de apoio à classificação e interpretação das repetições, incluindo organização por similaridade, agrupamento automático, classificação supervisionada e curadoria especializada. Esse objetivo foi atendido por meio da classificação por faixas, da curadoria manual das repetições, do agrupamento automático com HDBSCAN, da classificação supervisionada com RF e da separação entre classe manual e classe sugerida pelo modelo.

8.3 Principais Contribuições

A primeira contribuição deste trabalho foi a realização de uma revisão sistemática da literatura sobre análise e classificação de movimentos humanos com apoio de técnicas computacionais e métodos de IA. Essa revisão permitiu organizar evidências sobre tipos de captura, tecnologias utilizadas, abordagens de modelagem e desafios presentes na literatura, além de identificar lacunas que orientaram o desenvolvimento da solução proposta.

A segunda contribuição foi a definição de uma arquitetura computacional para análise de movimentos humanos em reabilitação física e neurofuncional. Essa arquitetura organiza o fluxo desde a aquisição ou importação do vídeo até a geração de saídas analíticas e relatórios, passando por extração de pose, cálculo de ângulos, segmentação, atributos por repetição, agrupamento e classificação.

A terceira contribuição foi a implementação do eMove como uma solução aplicada, capaz de processar dados de movimento, organizar sessões por paciente, tratamento e movimento/protocolo, segmentar repetições, extrair atributos e apoiar o acompanhamento longitudinal. A inclusão do tratamento como contexto das sessões fortalece a organização dos dados e permite acompanhar a avaliação da evolução funcional de forma mais estruturada.

A quarta contribuição foi a consolidação de um pipeline completo para análise de movimentos humanos. O pipeline integra aquisição de vídeo, extração de pose, cálculo angular, segmentação em repetições, extração de atributos, agrupamento automático, classificação supervisionada e geração de relatórios. Embora diversas pesquisas explorem partes isoladas desse processo, a integração dessas etapas em uma única aplicação configurável representa uma contribuição prática para estudos de reabilitação física e neurofuncional.

A quinta contribuição foi a evolução da análise para o nível de repetição. Em vez de considerar apenas a sessão como unidade principal de análise, o sistema passou a representar cada repetição por atributos próprios, como amplitude, compensação, duração e medidas de similaridade temporal. Essa mudança permitiu identificar padrões recorrentes e diferenças entre execuções que poderiam permanecer ocultas em análises agregadas da sessão.

A sexta contribuição foi a incorporação de mecanismos de apoio à classificação e curadoria especializada. O sistema permite classificação por faixas, revisão manual, agrupamento automático e classificação supervisionada com atributos tabulares. Durante a evolução do trabalho, a estratégia de agrupamento baseada em k-medoids foi substituída por HDBSCAN, enquanto a classificação supervisionada baseada em k-NN foi substituída por RF, tornando o pipeline mais adequado aos dados reais observados durante o desenvolvimento.

A sétima contribuição foi a disponibilização do eMove para utilização em ambientes de pesquisa externos ao contexto de desenvolvimento. Durante este trabalho, a plataforma foi instalada e disponibilizada para avaliação no Laboratório de Interfaces e Visualização (LIV), da UNESP, e no Laboratório de Informática em Saúde e Inovação (LISI), da PUC-Campinas. Posteriormente, também foi implantada no Laboratório de Reabilitação Virtual (LRV), da PUC-Campinas, no Laboratório de Cinesiologia Aplicada (LCA), no Laboratório de Avaliação Visual (LAV) e no PhINeR Lab, da UNICAMP, além do Laboratório de Comportamento Motor, da UFSCar.

Essa iniciativa ampliou o potencial de utilização do eMove em diferentes contextos de pesquisa, estabelecendo a infraestrutura necessária para a geração de bases de dados e para futuras etapas de avaliação, validação clínica e evolução colaborativa da plataforma.

Por fim, destaca-se a preocupação com privacidade, segurança e rastreabilidade. A implementação passou a considerar autenticação, organização multiempresa, compartilhamento controlado de pacientes, proteção de dados sensíveis, ocultação de informações em relatórios e atualização da aplicação, aspectos importantes para o uso da solução em ambientes reais.

8.4 Limitações

Apesar dos avanços obtidos, este trabalho apresenta limitações. A primeira delas está relacionada à quantidade de dados rotulados disponíveis para treinamento supervisionado. Embora a infraestrutura necessária para classificação supervisionada já tenha sido implementada, a base de exemplos rotulados ainda se encontra em expansão.

Outra limitação está relacionada à ausência de validação clínica dos resultados. Neste trabalho foi realizada uma avaliação computacional dos agrupamentos utilizando os dados do grupo de estudo apresentado no Capítulo 7 (Tabela 13). Entretanto, a interpretação dos grupos e a atribuição inicial de rótulos descritivos foram realizadas pelo autor, com caráter exploratório. Dessa forma, os resultados apresentados não devem ser entendidos como uma validação clínica formal dos agrupamentos. Essa coleta foi realizada no âmbito do grupo de estudos, sob o Certificado de Apresentação de Apreciação Ética (CAAE) nº 90387325.1.0000.5404.

A qualidade da captura por vídeo também pode influenciar os resultados. Condições de iluminação, enquadramento, oclusões, roupas e posicionamento corporal podem afetar a estimativa de pose e, consequentemente, os ângulos e atributos calculados. Embora o sistema possua etapas de pré-processamento e configuração, esses fatores ainda precisam ser considerados durante a coleta.

Também há limitações relacionadas à generalização dos modelos. Como os dados podem variar significativamente entre pacientes, tratamentos e movimentos, é necessário cuidado ao interpretar classificações sugeridas automaticamente. O sistema deve ser entendido como apoio à análise dos profissionais da saúde (especialistas em Cinesiologia), e não como ferramenta de diagnóstico ou decisão terapêutica autônoma.

A interpretabilidade também permanece como ponto de evolução. O eMove já utiliza atributos compreensíveis, relatórios, curadoria especializada e separação entre classes manuais e sugeridas. No entanto, técnicas formais de XAI ainda não foram incorporadas como etapa consolidada do pipeline.

Por fim, embora recursos voltados à privacidade e à segurança tenham sido implementados, a adequação completa a políticas institucionais e processos formais de uso de dados em saúde ainda exige aprofundamento. Aspectos como consentimento, auditoria detalhada, retenção de dados e integração com protocolos institucionais devem ser considerados em etapas futuras.

8.5 Trabalhos Futuros

Como trabalhos futuros, recomenda-se ampliar a base de dados com maior número de sessões, pacientes, movimentos/protocolos e profissionais envolvidos na curadoria. Essa ampliação permitirá avaliar melhor o desempenho dos modelos supervisionados e a robustez do pipeline em diferentes condições de uso.

Também é importante realizar estudos de validação com profissionais da saúde (especialistas em Cinesiologia), buscando verificar a coerência clínica dos agrupamentos identificados pelo sistema, a adequação dos rótulos sugeridos e a utilidade prática das informações apresentadas durante o acompanhamento funcional. Essa etapa permitirá complementar a avaliação computacional realizada neste trabalho com uma validação especializada em contexto real de uso.

Outra possibilidade é aprofundar a comparação entre modelos de classificação supervisionada. Embora o RF tenha se mostrado mais adequado à representação tabular adotada no pipeline atual, novos experimentos poderão comparar diferentes algoritmos, estratégias de validação e formas de seleção de atributos.

A incorporação de técnicas formais de XAI também representa uma direção importante. Métodos de explicabilidade podem ser utilizados para indicar quais atributos mais influenciaram uma determinada classificação, contribuindo para aumentar a transparência e a confiança dos profissionais da saúde na sugestão apresentada pelo sistema.

Os relatórios também podem ser aprimorados com novas formas de visualização, indicadores longitudinais e comparações entre sessões ou fases do tratamento. A evolução desses relatórios pode contribuir para uma comunicação mais clara entre profissionais da saúde, paciente e demais envolvidos no acompanhamento.

Também podem ser exploradas melhorias na captura e no processamento dos dados, como suporte a diferentes câmeras, avaliação de múltiplos planos de gravação, análise comparativa entre membros e integração com sensores complementares quando necessário.

Por fim, pretende-se avançar na validação do eMove em ambientes clínicos, ambulatoriais e de pesquisa aplicada, incluindo laboratórios parceiros e profissionais da área. Essa etapa será essencial para avaliar o impacto da solução em cenários reais, identificar limitações práticas e orientar novas versões do sistema.

Dessa forma, este trabalho contribui para a aproximação entre técnicas computacionais de análise de movimento e a prática de acompanhamento em reabilitação física e neurofuncional. Embora o eMove ainda demande ampliação da base de dados, validações com profissionais da saúde e evolução de alguns componentes do pipeline, os resultados obtidos demonstram a viabilidade da proposta e a capacidade da solução em transformar vídeos de movimento em informações estruturadas, rastreáveis e potencialmente úteis para o acompanhamento da avaliação da evolução funcional ao longo do tempo.

Referências

ACM. *About the ACM Digital Library*. 2024. <https://dlnext.acm.org/about>. Accessed: 07-09-2024. Citado na página 36.

AGUILAR-ORTEGA, R. et al. Uco physical rehabilitation: New dataset and study of human pose estimation methods on physical rehabilitation exercises. *Sensors*, v. 23, n. 21, p. 8862, 2023. Citado na página 19.

ALSOBHI, M. et al. Physical therapists' knowledge and attitudes regarding artificial intelligence applications in health care and rehabilitation: Cross-sectional study. *J Med Internet Res*, v. 24, n. 10, p. e39565, Oct 2022. ISSN 1438-8871. Disponível em: <https://doi.org/10.2196/39565>. Citado na página 28.

BENSALAH, A. et al. Easing automatic neurorehabilitation via classification and smoothness analysis. In: CARMONA-DUARTE, C. et al. (Ed.). *Intertwining Graphonomics with Human Movements*. Cham: Springer International Publishing, 2022. p. 336–348. ISBN 978-3-031-19745-1. Citado na página 32.

BERNDT, D. J.; CLIFFORD, J. Using dynamic time warping to find patterns in time series. In: *Proceedings of the 3rd International Conference on Knowledge Discovery and Data Mining*. [S.l.]: AAAI Press, 1994. (AAAIWS'94), p. 359–370. Citado 2 vezes nas páginas 31 e 32.

BILESAN, A. et al. Markerless human motion tracking using microsoft kinect sdk and inverse kinematics. *IEEE*, 2019. Citado 4 vezes nas páginas 29, 43, 50 e 56.

BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006. Citado 2 vezes nas páginas 19 e 24.

BOLAND, A. *Systematic review: A student's guide*. [S.l.]: SAGE Publications, 2013. 240 p. Citado na página 35.

CAMPELLO, R. J. G. B.; MOULAVI, D.; SANDER, J. Density-based clustering based on hierarchical density estimates. In: PEI, J. et al. (Ed.). *Advances in Knowledge Discovery and Data Mining*. Berlin, Heidelberg: Springer, 2013. (Lecture Notes in Computer Science, v. 7819), p. 160–172. Citado 2 vezes nas páginas 80 e 88.

CAPES. *Quem somos*. 2024. <https://www-periodicos-capes-gov-br.ezl.periodicos.capes.gov.br/index.php/sobre/quem-somos.html>. Accessed: 07-09-2024. Citado na página 36.

CASTILLO, S. et al. Optimization model for development of digital interactive exercises for cognitive rehabilitation. *IEEE*, 2019. Citado 2 vezes nas páginas 43 e 56.

DEBNATH, B. et al. A review of computer vision-based approaches for physical rehabilitation and assessment. *Multimedia Systems*, v. 28, n. 1, p. 209–239, 2022. Citado 2 vezes nas páginas 18 e 30.

FRANGOUDES, F. et al. Assessing human motion during exercise using machine learning: A literature review. *IEEE Access*, v. 10, p. 86874–86903, 2022. Citado 2 vezes nas páginas 24 e 32.

GEMAN, O. et al. An intelligent assistive tool using exergaming and response surface methodology for patients with brain disorders. *IEEE*, 2019. Citado 5 vezes nas páginas 24, 27, 43, 50 e 57.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Disponível em <http://www.deeplearningbook.org>. Citado 2 vezes nas páginas 19 e 24.

Google AI Edge. *Pose landmark detection guide*. 2026. MediaPipe Solutions. Acesso em: 6 jun. 2026. Disponível em: <https://ai.google.dev/edge/mediapipe/solutions/vision/pose_landmarker>. Citado 2 vezes nas páginas 67 e 75.

GUNNING, D.; AHA, D. Darpa's explainable artificial intelligence program. *AI Magazine*, v. 40, n. 2, p. 44–58, 2019. Citado na página 33.

HE, M. et al. Flexible and stretchable triboelectric nanogenerator fabric for biomechanical energy harvesting and self-powered dual-mode human motion monitoring. *CAPES*, 2021. Citado 4 vezes nas páginas 27, 44, 50 e 57.

HELLSTEN, T. et al. The potential of computer vision-based marker-less human motion analysis for rehabilitation. *Rehabilitation Process and Outcome*, v. 10, p. 11795727211022330, 2021. Citado 2 vezes nas páginas 19 e 30.

IEEE. *About IEEE Xplore*. 2024. <https://ieeexplore.ieee.org/Xplorehelp/overview-of-ieee-xplore/about-ieee-xplore>. Accessed: 07-09-2024. Citado na página 36.

ITAKURA, F. Minimum prediction residual principle applied to speech recognition. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, v. 23, n. 1, p. 67–72, 1975. Citado na página 31.

JIRAK, D. et al. Echo state networks and long short-term memory for continuous gesture recognition: a comparative study. *Cognitive Computation*, v. 15, 2023. ISSN 1866-9964. Disponível em: <https://doi.org/10.1007/s12559-020-09754-0>. Citado 10 vezes nas páginas 28, 44, 47, 48, 50, 51, 52, 53, 54 e 57.

KAUFMAN, L.; ROUSSEEUW, P. J. Partitioning around medoids (program pam). In: ____. *Finding Groups in Data: An Introduction to Cluster Analysis*. [S.l.]: John Wiley & Sons, 1990. cap. 2, p. 68–125. Citado na página 88.

KEOGH, E.; RATANAMAHATANA, C. A. Exact indexing of dynamic time warping. *Knowledge and Information Systems*, v. 7, n. 3, p. 358–386, 2005. Citado na página 32.

LAM, W. W. T.; TANG, Y. M.; FONG, K. N. K. A systematic review of the applications of markerless motion capture (mmc) technology for clinical measurement in rehabilitation. *Journal of NeuroEngineering and Rehabilitation*, BioMed Central, v. 20, n. 1, p. 57, 2023. Disponível em: <https://doi.org/10.1186/s12984-023-01186-9>. Citado na página 26.

LI, R. et al. Skeleton-based action recognition with key-segment descriptor and temporal step matrix model. *IEEE*, 2019. Citado 3 vezes nas páginas 43, 50 e 56.

LIU, C. et al. Video-based compensatory movement assessment for supporting upper limb rehabilitation evaluation. In: *Studies in Health Technology and Informatics*. [s.n.], 2025. v. 329, p. 1044–1048. Disponível em: <https://doi.org/10.3233/SHTI250998>. Citado 4 vezes nas páginas 24, 26, 31 e 33.

MARQUES, A. P. *Manual de Goniometria*. 2. ed. Barueri, SP: Manole, 2003. ISBN 85-204-1627-6. Citado 2 vezes nas páginas 18 e 26.

MCCARTHY, J. *What is Artificial Intelligence?* [S.l.]: Stanford University, 2006. Disponível em <http://jmc.stanford.edu/articles/whatisai/whatisai.pdf>. Citado na página 22.

MCINNES, L.; HEALY, J.; MELVILLE, J. UMAP: Uniform manifold approximation and projection for dimension reduction. *arXiv preprint arXiv:1802.03426*, 2018. Citado na página 90.

MIGUEL, G. R. *Uma Combinação da Visão Computacional e Inteligência Artificial para Analisar Movimentos em Apoio à Reabilitação de Pacientes Pós Acidente Vascular Cerebral*. Dissertação (Dissertação (Mestrado em Ciência da Computação)) — Universidade Estadual Paulista "Júlio de Mesquita Filho", Instituto de Biociências, Letras e Ciências Exatas, Bauru, SP, Brasil, mar. 2024. Disponível em: <https://hdl.handle.net/11449/256196>. Citado na página 29.

MILLER, T. Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*, v. 267, p. 1–38, 2019. Citado 2 vezes nas páginas 32 e 33.

MORANDO, M.; TROMBINI, M.; DELLEPIANE, S. Application of svm for evaluation of training performance in exergames for motion rehabilitation. *ACM*, 2019. Citado 4 vezes nas páginas 43, 48, 53 e 56.

MU, P.; DAI, M.; MA, X. Application of artificial intelligence in rehabilitation assessment. *CAPES*, 2021. Citado 3 vezes nas páginas 23, 43 e 57.

MÜLLER, M. *Information Retrieval for Music and Motion*. [S.l.: s.n.], 2007. ISBN 978-3-540-74047-6. Citado na página 31.

OpenCV. *OpenCV Documentation*. 2026. Acesso em: 6 jun. 2026. Disponível em: <https://docs.opencv.org/4.x/>. Citado na página 75.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Citado 5 vezes nas páginas 80, 88, 90, 93 e 95.

RAO, Y. Research on different convolutional neural networks in the classification scenes of yoga poses based on openpose extraction. *IEEE*, 2022. Citado 4 vezes nas páginas 24, 27, 44 e 56.

RODRIGUES, L. G. S. *O Uso da Realidade Aumentada e Aprendizado de Máquina na Reabilitação de Pacientes Pós-Acidente Vascular Cerebral*. Dissertação (Dissertação de Mestrado Acadêmico em Ciência da Computação) — Universidade Estadual Paulista "Júlio de Mesquita Filho", Faculdade de Ciências, Bauru, São Paulo, Brasil, set. 2022. Citado na página 28.

ROSIQUE, F.; LOSILLA, F.; NAVARRO, P. J. Applying vision-based pose estimation in a telerehabilitation application. *Applied Sciences*, v. 11, n. 19, p. 9132, 2021. Citado na página 18.

SAKOE, H.; CHIBA, S. Dynamic programming algorithm optimization for spoken word recognition. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, v. 26, n. 1, p. 43–49, 1978. Citado na página 31.

SAMPAIO, R. Estudos de revisão sistemática: Um guia para síntese criteriosa da evidência científica. *Revista Brasileira de Fisioterapia - REV BRAS FISIOTER*, v. 11, February 2007. Citado na página 35.

SEO, K. et al. Forecasting the walking assistance rehabilitation level of stroke patients using artificial intelligence. *CAPES*, 2021. Citado 5 vezes nas páginas 23, 24, 28, 43 e 57.

SHI, L.-F. et al. Gait recognition via random forests based on wearable inertial measurement unit. *Journal of Ambient Intelligence and Humanized Computing*, v. 11, 2020. ISSN 1868-5145. Disponível em: <https://doi.org/10.1007/s12652-020-01870-x>. Citado 3 vezes nas páginas 43, 53 e 57.

SHI, X. et al. Feature extraction and classification of lower limb motion based on semg signals. *IEEE*, 2020. Citado 4 vezes nas páginas 28, 43, 50 e 57.

SHORTLIFFE, E. H.; SEPÚLVEDA, M. J. Clinical decision support in the era of artificial intelligence. *JAMA*, v. 320, n. 21, p. 2199–2200, 2018. Citado 2 vezes nas páginas 32 e 33.

SOCCINI, A. M.; CENA, F. The ethics of rehabilitation in virtual reality: the role of self-avatars and deep learning. *IEEE*, 2021. Citado 2 vezes nas páginas 44 e 56.

STENUM, J. et al. Clinical gait analysis using video-based pose estimation: Multiple perspectives, clinical populations, and measuring change. *PLOS Digital Health*, v. 3, n. 3, p. e0000467, 2024. Disponível em: <https://doi.org/10.1371/journal.pdig.0000467>. Citado na página 26.

STUART, B.; MARTYN, P. *Biomechanics of Human Movement: Basics and Beyond*. Champaign, IL, USA: Human Kinetics, 2018. Citado na página 18.

SU, Y.; SU, L. Intelligent medical rehabilitation training instrument based on movement coordination. *IEEE*, 2020. Citado 4 vezes nas páginas 24, 27, 43 e 56.

THARATIPYAKUL, A.; SRIKAEWSIEW, C.; PONGNUMKUL, S. Deep learning-based human body pose estimation in providing feedback for physical movement: A review. *Heliyon*, v. 10, n. 18, p. e36589, 2024. Citado 2 vezes nas páginas 19 e 30.

TOPOL, E. J. *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. [S.l.]: Basic Books, 2019. ISBN 9781541644632. Citado na página 23.

TSAI, M.-F.; HUANG, S.-H. Enhancing accuracy of human action recognition system using skeleton point correction method. *Multimedia Tools and Applications*, v. 81, 2022. ISSN 1573-7721. Disponível em: <https://doi.org/10.1007/s11042-022-12000-4>. Citado 6 vezes nas páginas 23, 25, 30, 44, 53 e 57.

TURING, A. M. Computing machinery and intelligence. *Mind*, Oxford University Press, v. 59, n. 236, p. 433–460, 1950. Citado na página 22.

ULLAH, R. et al. A real time action scoring system for movement analysis and feedback in physical therapy using human pose estimation. *Scientific Reports*, v. 15, n. 1, p. 44784, 2025. Disponível em: <https://doi.org/10.1038/s41598-025-29062-7>. Citado 3 vezes nas páginas 26, 27 e 33.

WAGH, V. et al. Using mediapipe to track upper-limb reaching movements after stroke: a proof-of-principle study. *Journal of NeuroEngineering and Rehabilitation*, v. 22, p. 268, 2025. Disponível em: <https://doi.org/10.1186/s12984-025-01808-4>. Citado na página 26.

WANG, C. et al. Dense attention network for facial expression recognition in the wild. *ACM*, 2020. Citado 4 vezes nas páginas 28, 43, 47 e 56.

WANG, J. et al. Surface electromyography based estimation of knee joint angle by using correlation dimension of wavelet coefficient. *IEEE*, 2019. Citado 2 vezes nas páginas 43 e 56.

WANG, Z. et al. Attention-based vision transformer for human activity classification using mmwave radar. *ACM*, 2023. Citado 5 vezes nas páginas 29, 44, 46, 54 e 56.

WU, L. F. Evaluation on multimodal dance action recognition based on artificial intelligence image technology. *ACM*, 2023. Citado 2 vezes nas páginas 44 e 56.

YADAV, N. et al. Data privacy in healthcare: In the era of artificial intelligence. *Indian Dermatology Online Journal*, v. 14, n. 6, p. 788–792, 2023. Citado na página 19.

ZENG, Z. Research on multimodal dance movement recognition based on artificial intelligence image technology. *Computational Intelligence and Neuroscience*, v. 2022, n. 1, p. 4785333, 2022. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1155/2022/4785333>. Citado 2 vezes nas páginas 23 e 53.

ZENG, Z.; XIE, L. Upper-limb movement classification using semg signals based on deep residual shrink network. *IEEE*, 2022. Citado 9 vezes nas páginas 27, 33, 44, 47, 49, 51, 52, 53 e 56.

ZHANG, C. et al. An end-to-end lower limb activity recognition framework based on semg data augmentation and enhanced capsnet. *CAPES*, 2023. Citado 7 vezes nas páginas 28, 44, 47, 50, 51, 53 e 57.

ZHANG, Z. et al. A human activity recognition method using wearable sensors based on convtransformer model. *CAPES*, 2023. Citado 6 vezes nas páginas 22, 23, 44, 50, 53 e 57.

ZHENG, W.; JING, P.; XU, Q. Action recognition based on spatial temporal graph convolutional networks. *ACM*, 2019. Citado 10 vezes nas páginas 24, 28, 43, 47, 48, 49, 51, 52, 54 e 56.