

Gabriel Rissatti Miguel

**Uma Combinação da Visão Computacional e
Inteligência Artificial para Analisar Movimentos
em Apoio à Reabilitação de Pacientes Pós
Acidente Vascular Cerebral**

Bauru, São Paulo, Brasil

Março 2024

Gabriel Rissatti Miguel

Uma Combinação da Visão Computacional e Inteligência Artificial para Analisar Movimentos em Apoio à Reabilitação de Pacientes Pós Acidente Vascular Cerebral

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"

Instituto de Biociências, Letras e Ciências Exatas

Programa de Pós-Graduação em Ciência da Computação

Orientador: Dr. José Remo Ferreira Brega

Bauru, São Paulo, Brasil

Março 2024

*Este trabalho é dedicado à todas vítimas de AVC e espero contribuir com uma ferramenta
que auxilie na reabilitação motora.*

M636c Miguel, Gabriel Rissatti
Uma combinação da Visão Computacional e Inteligência Artificial para analisar movimentos em apoio à reabilitação de pacientes pós Acidente Vascular Cerebral / Gabriel Rissatti Miguel. -- Bauru, 2024
93 p.

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

1. Visão Computacional. 2. Inteligência Artificial. 3. Análise de movimentos. 4. Reabilitação. 5. AVC. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Universidade Estadual Paulista (UNESP), Faculdade de Ciências, Bauru. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE GABRIEL RISSATTI MIGUEL, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO, DA FACULDADE DE CIÊNCIAS - CÂMPUS DE BAURU.

Aos 17 dias do mês de junho do ano de 2024, às 14:00 horas, por meio de Videoconferência, realizou-se a defesa de DISSERTAÇÃO DE MESTRADO de GABRIEL RISSATTI MIGUEL, intitulada **Uma Combinação da Visão Computacional e Inteligência Artificial para Analisar Movimentos em Apoio à Reabilitação de Pacientes Pós Acidente Vascular Cerebral**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. JOSE REMO FERREIRA BREGA (Orientador(a) - Participação Virtual) do(a) Departamento de Computação / UNESPCâmpus de Bauru, Prof. Dr. RODOLFO IPOLITO MENEGUETTE (Participação Virtual) do(a) Instituto de Ciências Matemáticas e de Computação / Universidade de São Paulo, Prof. Dr. MÁRIO POPOLIN NETO (Participação Virtual) do(a) Instituto Federal de São Paulo. 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: 2024.06.17 16:00:39
-03'00'

Prof. Dr. JOSE REMO FERREIRA BREGA

Agradecimentos

Em primeiro lugar agradeço a Deus pela minha vida de forma geral, aos meus pais Marcia e Miguel por todo sacrifício e priorização em minha educação que sempre tiveram, minha esposa Clara, meu irmão Rafael, minha amiga e grande colaboradora deste trabalho a fisioterapeuta Priscila Afonso, minha tia Fátima pelo suporte oferecido no início de minha vida acadêmica que sou muito grato assim como o Alexandre Marcelino me ajudou muito, agradeço também a Débora, Alaor e as boas almas que me acompanham e guiam.

A todos meus professores que tive em toda trajetória, em especial ao Dr. José Remo Ferreira Brega, qual considero como grande inspiração, assim como João Nelson do Nascimento e Cibele Carrara.

Agradeço também ao Alexandre Brandão que muito tem contribuído e também a banca examinadora e por fim ao Centro Paula Souza que contribuiu para que eu tivesse tempo livre para estudar.

Por fim, agradeço também meus alunos que me apoiaram neste projeto: Bárbara Pelicer, Caio Rogers, Leticia Correa, Lyvia Eduarda, Marilia Souza, Pedro Henrique, Samara Souza, Silvio Pereira e Victor Resende.

“Cada boa ação que você pratica é uma luz que você cria em torno de seus próprios passos.”

Chico Xavier

Resumo

Estudos sobre Visão Computacional e Inteligência Artificial estão sendo realizados ao redor do mundo. Muitos destes trabalhos aplicam a classificação de movimentos para auxiliar pacientes com problemas motores que precisam de reabilitação fisioterápica, dentre as causas das lesões que geram as dificuldades motoras temos o Acidente Vascular Cerebral (AVC). Esta dissertação apresenta uma Revisão Sistemática da Literatura para encontrar estudos sobre visão computacional e classificação de movimentos. Este trabalho apresenta também uma proposta de uma aplicação que une Visão Computacional e Inteligência Artificial para analisar movimentos de sessões de reabilitação de pacientes que sofreram AVC, a aplicação gera informações permitindo que profissional de saúde responsável pelo processo de reabilitação motora analise uma sessão específica ou a evolução do paciente, os movimentos são configurados pelo profissional de saúde responsável pelo processo de reabilitação motora, tornando o sistema flexível para que diversos movimentos possam ser estudados. A principal contribuição do trabalho é a ferramenta resultante que visa auxiliar o processo de reabilitação motora de pessoas que sofreram AVC.

Palavras-chave: visão computacional. inteligência artificial. análise de movimentos. reabilitação. AVC.

Abstract

Studies on Computer Vision and Artificial Intelligence are being carried out around the world. Many of these studies apply movement classification to help patients with motor problems who need physiotherapy rehabilitation. Among the causes of injuries that lead to motor difficulties are strokes. stroke. This dissertation presents a Systematic Literature Review to find studies on computer vision and movement classification. This work presents also a proposal for an application that combines Computer Vision and Intelligence Artificial to analyze movements of rehabilitation sessions of patients who have suffered stroke, the application generates information allowing the health professional responsible for the motor rehabilitation process, analyze a specific session or the patient's evolution, the movements are configured by the health professional responsible for the process of motor rehabilitation, making the system flexible so that different movements can be studied. The main contribution of the work is the resulting tool that aims to assist the process of motor rehabilitation for people who have suffered a stroke

Keywords: computer vision. artificial intelligence. motion analysis. rehabilitation. stroke.

Lista de ilustrações

Figura 1 – Aplicativo RehabGesture.	17
Figura 2 – Etapas da Visão Computacional.	22
Figura 3 – Divisões do HAR.	24
Figura 4 – Fluxo de triagem.	30
Figura 5 – Trabalhos aprovados e os reprovados por etapa de triagem.	31
Figura 6 – Trabalhos aprovados conforme ano de publicação.	32
Figura 7 – Quantia e porcentagem de artigos conforme autoria do dataset.	37
Figura 8 – Quantidade de artigos conforme tipo de captura do dataset.	39
Figura 9 – Exemplo do dataset UI-PRMD.	40
Figura 10 – Datasets mais utilizados.	41
Figura 11 – Linguagens utilizadas nos trabalhos.	44
Figura 12 – Abordagens utilizadas nos trabalhos.	46
Figura 13 – Diagrama de caso de uso.	52
Figura 14 – Combinação de Visão Computacional e IA para detectar articulações do corpo humano.	53
Figura 15 – IDE PyCharm	56
Figura 16 – Polígono construído com OpenCV	57
Figura 17 – Detecção de pontos corporais	58
Figura 18 – Interface gráfica construída com Tkinter	59
Figura 19 – Recuperação de dados do SQLite	60
Figura 20 – Representação em camadas das tecnologias	60
Figura 21 – Representação do diagrama de dados.	63
Figura 22 – Diagrama de interações do tipo sequência.	64
Figura 23 – Cadastro de Pacientes.	65
Figura 24 – Ilustração da formação de ângulos.	67
Figura 25 – Cadastro de movimentos.	68
Figura 26 – Formação de um ângulo pelos segmentos de retas.	69
Figura 27 – Parametrização de ângulos.	70
Figura 28 – Manual para a parametrização de ângulos.	71
Figura 29 – Projeção do paciente na aplicação.	73
Figura 30 – Representação gráfica em um polígono verde do ângulo esperado.	74
Figura 31 – Representação gráfica em um polígono vermelho do ângulo de compen- sação.	74
Figura 32 – Representação gráfica de ambos ângulos.	75
Figura 33 – Representação gráfica de ambos ângulos.	75
Figura 34 – Indicação de posicionamento incorreto.	76

Figura 35 – Recuperação de algumas colunas da tabela sessao_item.	77
Figura 36 – Pesquisa da sessão.	78
Figura 37 – Vizualização da sessão.	78
Figura 38 – Função CalcAngulo.	79
Figura 39 – Recuperação de alguns registros de uma sessao da tabela sessao_angulo..	80
Figura 40 – Detalhes da sessão.	81
Figura 41 – Análise entre sessões.	82
Figura 42 – Sessões ainda não integradas com Rebase.	83
Figura 43 – Dados enviados para o cadastro da sessão.	83
Figura 44 – Dados enviados para o vinculação de movimentos na sessão.	84
Figura 45 – Visualização do código gerado pelo Rebase.	85

Lista de tabelas

Tabela 1 – Primeira <i>string</i> de pesquisa.	28
Tabela 2 – Segunda <i>string</i> de pesquisa utilizada.	28
Tabela 3 – Terceira <i>string</i> de pesquisa utilizada.	29
Tabela 4 – Quantidade de documentos retornados por bases científicas.	29
Tabela 5 – Quantidade de documentos aprovados por bases científicas.	32
Tabela 6 – Lista de documentos aprovados.	33
Tabela 7 – Lista de documentos conforme autoria do dataset.	37
Tabela 8 – Lista de artigos conforme tipo do dataset.	39
Tabela 9 – Lista de artigos conforme datasets.	42
Tabela 10 – Lista de artigos conforme linguagem de programação.	45
Tabela 11 – Lista de artigos conforme abordagem.	47
Tabela 12 – Combinações de artigos selecionados	49

Lista de abreviaturas e siglas

ACM	Associação para Máquinas de Computação, (do inglês <i>Association for Computing Machinery</i>)
API	Interface de programação de aplicações (do inglês <i>Application Programming Interface</i>)
AVC	Acidente Vascular Cerebral
BRAINN	Instituto Brasileiro de Neurociência e Neurotecnologia (do inglês, <i>Brazilian Institute of Neuroscience and Neurotechnology</i>)
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
HAR	O Reconhecimento da Ação Humana, (do inglês <i>Human Action Recognition</i>)
IA	Inteligência Artificial
IDE	Ambiente de Desenvolvimento Integrado, (do inglês <i>Integrated Development Environment</i>)
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos, (do inglês <i>Institute of Electrical and Electronics Engineers</i>)
REBASE	Banco de dados de reabilitação, (do inglês <i>Rehabilitation Database</i>)
RSL	Revisão Sistemática da Literatura
VPN	Rede Privada Virtual, (do inglês <i>Virtual Private Network</i>)
XAI	Inteligência Artificial Explicável (do inglês, <i>Explainable Artificial Intelligence</i>)

Sumário

1	INTRODUÇÃO	15
1.1	Considerações sobre Acidente Vascular Cerebral	15
1.2	Trabalhos Relacionados	16
1.3	Justificativa	17
1.4	Objetivos	18
1.5	Metodologia	18
1.6	Organização do Trabalho	19
1.7	Considerações Finais do Capítulo	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Considerações Iniciais do Capítulo	20
2.2	Inteligência Artificial	20
2.3	Inteligência Artificial Explicável	20
2.4	Visão Computacional	21
2.5	Estimativa de Pose e Reconhecimento da Ação Humana	23
2.6	Considerações Finais do Capítulo	24
3	REVISÃO SISTEMÁTICA DA LITERATURA	25
3.1	Considerações Iniciais do Capítulo	25
3.2	Etapas	25
3.3	Análise e Discussão dos Resultados	35
4	ESPECIFICAÇÃO DA SOLUÇÃO	51
4.1	Considerações Iniciais do Capítulo	51
4.2	Cenário	51
4.3	Requisitos da aplicação	52
4.4	Tecnologias Escolhidas	55
4.5	Considerações Finais do Capítulo	60
5	DESENVOLVIMENTO	62
5.1	Considerações Iniciais do Capítulo	62
5.2	Banco de Dados	62
5.3	Funcionalidades	63
5.4	Funcionalidades de Entrada de Dados	64
5.5	Funcionalidades de Resultados	72
5.6	Considerações Finais do Capítulo	85

6	CONCLUSÃO	86
6.1	Considerações Iniciais do Capítulo	86
6.2	Atendimento aos Objetivos	86
6.3	Trabalhos Futuros e Continuidade	87
6.4	Considerações Finais	88
	REFERÊNCIAS	89

1 INTRODUÇÃO

1.1 Considerações sobre Acidente Vascular Cerebral

O Acidente Vascular Cerebral acontece quando vasos que levam sangue ao cérebro entopem ou se rompem, provocando a paralisia da área cerebral que ficou sem circulação sanguínea. É uma doença que acomete mais os homens e é uma das principais causas de morte, incapacitação e internações em todo o mundo. Quanto mais rápido for o diagnóstico e o tratamento do AVC, maiores serão as chances de recuperação completa ([SAÚDE, 2015](#)).

A maior parte dos sobreviventes do AVC permanecem com alguma sequela, seja ela de ordem física ou não. Para minimizar esses danos decorrentes do AVC é necessário que essa população tenha acesso aos serviços de reabilitação, com tratamento de forma integral, contemplando as reais necessidades desses usuários, observado suas capacidades e potencialidades. A Organização Mundial de Saúde define reabilitação como "O uso de todos os meios necessários para reduzir o impacto da condição incapacitante e permitir aos indivíduos incapacitados a obtenção de uma completa integração"([SCHIMIT CLARISSA SELAU, 2019](#)).

O tratamento para o AVC consiste em dois formatos, sendo eles a prevenção através de uma vida saudável se mantendo distante dos fatores de risco ou a reabilitação pós AVC a qual necessita de acompanhamento multiprofissional com foco no tratamento fisioterapêutico para as sequelas motoras. O acompanhamento fisioterapêutico é extremamente importante para o alcance da qualidade de vida do paciente. A fisioterapia motora proporciona melhorias na flexibilidade, coordenação motora e mobilidade, cooperando positivamente para a independência funcional dos pacientes ([SIQUEIRA PALOMA SCHNEIDERS, 2019](#)).

A execução de exercícios físicos de reabilitação normalmente é realizada em hospitais e clínicas, porém os pacientes recebem apenas um número limitado de sessões supervisionadas devido o alto custo. A realização correta destes exercícios de reabilitação de forma domiciliar é necessária para prover a recuperação total dos pacientes. Nos últimos anos foram propostos vários métodos de soluções utilizando Visão Computacional para avaliar corretamente a reabilitação física ([DU et al., 2021](#)).

Com base nestes argumentos é aceitável considerar que novas aplicações possam surgir para auxiliar no tratamento de pacientes que sofreram de AVC, apoiando os envolvidos com a análise dos exercícios, esta dissertação apresenta uma proposta que especifica uma pesquisa e apresenta uma aplicação que foi desenvolvida para auxiliar profissionais da área de reabilitação motora e pacientes através da captura e análise de

movimentos corporais das sessões.

1.2 Trabalhos Relacionados

Vários pesquisadores ao redor do mundo estão explorando e contribuindo com o uso da Inteligência Artificial para captura de movimentos com o intuito de auxiliar na reabilitação física dos pacientes.

O trabalho de [Du et al. \(2021\)](#) estabelece um método de aprendizado supervisionado para avaliar automaticamente os exercícios de reabilitação física, utilizando dentre os equipamentos uma câmera Kinect, segundo o autor, este trabalho promoverá uma técnica de baixo custo para avaliação do desempenho de exercícios de reabilitação física.

Já a pesquisa de [Park et al. \(2021\)](#) aborda o reconhecimento de ações do movimento humano para tratar a similaridade de movimentos, este estudo decompõe o corpo humano em partes que são formadas por combinações de coordenadas. Segundo o autor com a similaridade de movimentos é possível identificar se um movimento é bem executado ou não, todavia é um problema desafiador, dentre os obstáculos é citado a pouca quantidade de *datasets* de movimentos humanos.

Analisando o cenário de pesquisas no Brasil, pode-se destacar a área de Uso da Realidade Virtual na reabilitação de pacientes com AVC do *Brazilian Institute of Neuroscience and Neurotechnology* (BRAINN), segundo [Brandao \(2016\)](#), a *Gesture Collection*, que é um conjunto de aplicativos de Realidade Virtual que permite por meio de um sensor a interação por meio de gestos, que permite transformar atividades tradicionais de fisioterapia e terapia ocupacional em tarefas mais lúdicas.

Esta coleção do BRAINN é formada por cinco aplicativos voltados para profissionais de estudo do movimento humano, com aplicações nas áreas de reabilitação motora e neurofuncional, além de avaliação e treinamento físico de fisioterapia e terapia ocupacional ([BRANDAO, 2016](#)).

[Brandao \(2016\)](#) detalha o que contempla a *Gesture Collection*:

- *GestureMaps*: Com o uso de um avatar, permite a simulação da exploração de locais por meio do Google Street, o movimento necessário é marcha estacionária (simulação de caminhada sem sair do lugar);
- *GestureChess*: Jogo de xadrez virtual controlado pelas mãos;
- *GesturePuzzle*: Quebra cabeça com a possibilidade de arrastar as peças utilizando o movimento das mãos;
- *GestureChair*: Jogo baseado em fliperama que foca no movimento dos braços; e

- *RehabGesture*: Proporciona ao especialista a possibilidade de analisar em tempo real os movimentos necessários para atividades físicas, este aplicativo é ilustrado na Figura 1.

Figura 1 – Aplicativo RehabGesture.



Fonte - (BRANDAO, 2016)

O conjunto de aplicações *Gesture Collection* contempla membros superiores e inferiores.

Os estudos listados possuem grande importância no processo de reabilitação motora de pacientes, todavia tais aplicações ainda não contemplam que os movimentos a serem analisados sejam cadastrados pelo profissional de saúde responsável pelo processo de reabilitação motora para que possam ser analisados de forma detalhada conforme característica individual de cada paciente.

1.3 Justificativa

É de extrema importância que pacientes pós-AVC realizem o tratamento de reabilitação para sanarem suas dificuldades motoras, sistemas específicos para apoiarem o processo de reabilitação motora apresentam importância e são solicitados pelos profissionais de reabilitação motora. A aplicação apresentada nesta dissertação foi desenvolvida para contribuir diretamente neste processo de reabilitação motora permitindo que o profissional de saúde responsável pelo processo de reabilitação motora parametrize as sessões, grave os movimentos e tenha um histórico do paciente para acompanhar a evolução e pontos de melhoria além de poder reproduzir cada sessão em vídeo.

1.4 Objetivos

Esta dissertação é resultante de pesquisa e desenvolvimento científico e possui os seguintes objetivos:

Geral: entender as tendências sobre aplicações que utilizam Visão Computacional e IA na classificação de movimentos e apresentar uma aplicação para contribuir com o processo de reabilitação motora pós-AVC.

Específicos:

1- Realizar uma revisão sistemática de conteúdo acerca da utilização da Visualização da Informação e Inteligência Artificial aplicada à análise de movimentos;

2- Propor a arquitetura de uma solução parametrizável para diversos movimentos e que permita a gravação de sessões e consulta de resultados;

3- Aplicar o design proposto e desenvolver uma aplicação para registro de sessões de reabilitação motora pós-AVC e consultas de resultados;

4- Criar um mecanismo de entrada de dados parametrizável que consiga abranger situações distintas de pacientes para a alimentação de um *dataset* de movimentos para estudos futuros;

5- A partir dos dados parametrizados, ser possível registrar sessões de reabilitação motora de pacientes onde nestas sessões características dos movimentos sejam registradas;

6- Desenvolver rotinas para a visualização de resultados das sessões de forma gráfica e permitir que as sessões gravadas possam ser reproduzidas; e

7- Integrar os dados gerados nas sessões com uma ferramenta externa para contribuição científica e estudos futuros.

A contribuição almejada por essa aplicação é facilitar o processo de reabilitação motora tanto para o paciente quanto para o profissional de saúde responsável pelo processo de reabilitação, essa contribuição será por meio de uma aplicação configurável que combina Visualização da Informação e Inteligência Artificial, ambos poderão assistir às sessões anteriores, visualizar resultados através de ângulos gerados e discutir os resultados favorecendo a análise da evolução obtida e possíveis pontos de melhorias. Os dados gerados nas sessões serão registrados alimentarão um *dataset* de movimentos para estudos futuros e também poderão ser integrados à uma ferramenta externa para contribuição científica.

1.5 Metodologia

Partiu-se da hipótese de que a combinação da Visualização da Informação, Inteligência Artificial (IA) e Inteligência Artificial Explicável (XAI) podem auxiliar no processo

de reabilitação motora de pacientes que sofreram AVC. Desta forma, se executou uma revisão sistemática de literatura sobre a combinação da Visualização da Informação, IA e XAI. A partir desta revisão se elaborou uma proposta com a especificação de uma aplicação para auxiliar no processo de realibitação motora de pacientes que sofreram AVC.

1.6 Organização do Trabalho

Esta dissertação está organizada em mais cinco capítulos além da presente Introdução. No Capítulo 2 são expostos conceitos para fundamentar o restante do trabalho. No Capítulo 3 é apresentada a revisão sistemática de literatura realizada. No Capítulo 4 é descrita a especificação da ferramenta, o desenvolvimento da ferramenta juntamente com seus resultados são detalhados no Capítulo 5. Por fim, o Capítulo 6 contém a discussão do atendimento aos objetivos e a conclusão deste trabalho.

1.7 Considerações Finais do Capítulo

O AVC pode gerar sequelas motoras nos pacientes, para tratar esta situação é necessário o acompanhamento multiprofissional com foco no tratamento fisioterápico. Vários pesquisadores ao redor do mundo estão atuando em como a IA pode auxiliar em aplicações para captura de movimentos com o intuito de auxiliar na reabilitação física dos pacientes, porém nota-se que estudos atuais envolvem aplicações criadas para trabalharem com movimentos pré-programados, dentre os objetivos desta dissertação é apresentar uma solução configurável que possa atuar com movimentos parametrizados pelo profissional de saúde responsável pelo processo de reabilitação motora conforme a necessidade de cada paciente. No Capítulo 2 são apresentados os principais conceitos relacionados ao estudo.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Considerações Iniciais do Capítulo

Este capítulo apresenta os principais conceitos relacionados ao estudo, a qual pode-se destacar a IA, XAI, Visão Computacional, Estimativa de Pose e Reconhecimento da Ação Humana.

2.2 Inteligência Artificial

A ideia de se criar algo parecido com máquinas inteligentes ou uma inteligência paralela à nossa hoje são projetos onde trabalham cientistas de várias partes do mundo, tais cientistas trabalham em várias áreas de conhecimento, como linguística, psicologia, computação, etc. Uma característica em comum nos diferentes trabalhos é a ideia de que é possível criar "máquinas pensantes" e o caminho para isso é a elaboração de sofisticados softwares (TEIXEIRA, 2019).

A IA é um ramo da ciência que visa, por meios tecnológicos, ser capaz de simular a inteligência humana, podendo resolver problemas, criar soluções e até mesmo tomar decisões no lugar do ser humano, como um auxílio que facilitaria em diversas áreas do cotidiano. O termo IA foi falado por John McCarthy em 1956, em uma conferência sobre tecnologia no Dartmouth College, EUA, mas o assunto já era anteriormente discutido por Alan Turing em 1950, considerado pai da computação (SILVA, 2019).

A IA é amplamente usada para descrever as mais novas experiências de interação entre sistemas computacionais e seus usuários. Ela está transformando a maneira como nos comunicamos, como trabalhamos, como consumimos, como cuidamos da saúde, como programamos as férias, como pesquisamos, difícil encontrar uma atividade socioeconômica não mediada pelas tecnologias de IA (KAUFMAN, 2019).

2.3 Inteligência Artificial Explicável

Os sistemas de IA tiveram uma adoção significativa em vários domínios. Ao mesmo tempo, a adoção adicional em alguns domínios é prejudicado pela incapacidade de confiança plena em um sistema de IA. Além disso, justiça, privacidade, transparência e explicabilidade são vitais para desenvolver confiança nos sistemas de IA. A subárea de explicar os sistemas de IA passou a ser conhecida como XAI. A disponibilidade de grandes massas de dados em complemento aos modelos de redes neurais profundas aceleraram a adoção de sistemas

de IA no mundo real, devido ao seu sucesso significativo no Processamento de Linguagem Natural, Visão Computacional e outras tarefas com uso intensivo de dados. No entanto, apesar dos avanços no desempenho dessas tarefas, profundos modelos de aprendizagem permanecem uma caixa preta, ou seja, é extremamente difícil entender como as entradas são mapeadas para as saídas. (SHETH et al., 2021).

Segundo Murray, Stankovic e Stankovic (2020), um impulsionador para a pesquisa XAI é a recente legislação da União Europeia que permite que um cliente solicite explicações para as decisões tomadas por IA.

2.4 Visão Computacional


Segundo Backes (2016), a Visão Computacional pode ser definida como a área de conhecimento que tenta transmitir para máquinas a habilidade da visão, quando mencionado não pode-se limitar apenas na captura de imagens, esta captura é apenas o início de um rico processo que pode estender-se para retirada de ruídos, separação de regiões ou cena, extrair informações da imagem analisada e relacionar imagens.

Ainda segundo Backes (2016), um sistema de Visão Computacional pode ser dividido nas seguintes etapas:

- **Aquisição:** Esta etapa se refere a aquisição da imagem, tenta simular a função dos olhos, pode ser realizada por dispositivos como câmeras, scanners;
- **Processamento:** Responsável por aplicar técnicas como salientar bordas, remover ruídos com o intuito de melhorar as imagens;
- **Segmentação:** Divide a imagem em regiões de interesse, como por exemplo em uma paisagem, destacar apenas o céu;
- **Extração de características / Análise de imagens:** Responsável pela obtenção de conjuntos de características do objeto de interesse encontrando uma codificação numérica que representa a imagem; e
- **Reconhecimento de padrões:** Etapa que classifica / agrupa imagens com base nas características.

A Figura 2 ilustra estas etapas.

Figura 2 – Etapas da Visão Computacional.



Fonte - (BACKES, 2016) - Adaptado pelo autor.

Conforme Szeliski (2021), atualmente a Visão Computacional está sendo utilizada nas seguintes áreas:

- **Reconhecimento óptico de caracteres:** Reconhecimento óptico de caracteres, leitura de códigos postais manuscritos em cartas e reconhecimento automático de placas;
- **Inspeção de máquinas:** Inspeção rápida de peças para garantia de qualidade;
- **Varejo:** Reconhecimento de objetos para caixas e lojas totalmente automatizadas;
- **Armazéns:** Entrega autônoma de pacotes de transporte de paletes e coleta de peças por manipuladores robóticos;
- **Imagens médicas:** Registrar imagens pré-operatórias e intra-operatórias ou realizar estudos de longo prazo;
- **Veículos autônomos:** Capazes de conduzir ponto-a-ponto entre cidades, bem como voos autônomos;
- **Construção de modelos 3D:** Construção totalmente automatizada de modelos 3D de fotografias aéreas e de drones;
- **Movimentos partidas:** Mesclando imagens geradas por computador com imagens de ação ao vivo por rastreamento de pontos de recurso no vídeo de origem para estimar o movimento, tais técnicas são amplamente utilizadas em Hollywood;
- **Captura de movimento:** Usando marcadores retrorrefletivos vistos de várias câmeras ou outras técnicas baseadas em visão para capturar atores para animação por computador;
- **Vigilância:** Monitoramento de intrusos, análise de tráfego rodoviário e monitoramento de piscinas; e

- **Reconhecimento de impressão digital e biometria:** Utilizado para autenticação automática de acesso e em aplicações forenses.

2.5 Estimativa de Pose e Reconhecimento da Ação Humana

A estimativa de pose humana é um método fundamental para detectar o comportamento humano e é aplicada em cinematografia virtual usando Computação Gráfica, Reconhecimento de Ação Humana (HAR) e Sistemas de Segurança. A posição da articulação varia muito dependendo de vários fatores, como ângulo da câmera, roupas e contexto (KIM; LEE, 2020a).

O HAR visa reconhecer diferentes ações a partir de uma sequência de observações e diferentes condições ambientais. Uma ampla variedade é aplicável à pesquisa de reconhecimento de ação baseada em visão. Isso pode incluir vigilância por vídeo, rastreamento, assistência médica e interação humano-computador. Seu objetivo é reconhecer as ações de uma pessoa a partir de sensores ou dados visuais (AL-FARIS et al., 2020).

O HAR desempenha um papel vital em um sistema de saúde para reconhecer a atividade de reabilitação de pacientes como sua ação e comportamento para facilitar os processos de reabilitação. Um método HAR refere-se aos movimentos de uma ou mais partes do corpo humano e está frequentemente relacionado com o método de determinar e rotular eventos utilizando observação dependente de processamento de imagens e vídeo. Portanto, os sistemas HAR devem atribuir as mesmas tags para a mesma atividade, mesmo quando realizada por pessoas diferentes em condições ou ambientes diferentes. Os aplicativos HAR visam analisar e identificar automaticamente determinado comportamento humano usando o conhecimento obtido em vídeo por meio de análise de Visão Computacional (F; SINGH, 2021).

F e Singh (2021) e Boualia e Amara (2019) explicam que o HAR pode ser dividido em três níveis : Tecnologia, sistemas HAR e Aplicativos. A Figura 3 ilustra tais níveis.

Figura 3 – Divisões do HAR.



Fonte - [F e Singh \(2021\)](#) - Adaptado pelo autor

2.6 Considerações Finais do Capítulo

Aplicações de IA vem demonstrando toda sua importância e qualidade em diversas áreas e cada vez mais estão presentes na rotina da sociedade, cada vez mais explicações sobre as decisões tomadas por IA são requeridas. Já a área da Visão Computacional que tenta transmitir para máquinas a habilidade da visão, não apenas capturando mas também interpretando.

Se tratando de áreas tão distintas, objetivando especificar uma solução de qualidade, uma estratégia possível é fazer uma Revisão Sistemática da Literatura para um entendimento com a profundidade necessária para o problema.

3 REVISÃO SISTEMÁTICA DA LITERATURA

3.1 Considerações Iniciais do Capítulo

Neste capítulo são apresentados os métodos utilizados para construir este trabalho que empregou a Revisão Sistemática da Literatura (RSL) para encontrar estudos sobre visão computacional na classificação de movimentos.

A RSL é uma aborgagem de pesquisa que utiliza como fonte de dados as literaturas presentes sobre determinado assunto, este método fornece um resumo com as evidências atreladas a uma estratégia, tais revisões são úteis para integrar informações de conjuntos de dados específicos (SAMPAIO, 2007).

3.2 Etapas

Conforme Boland Angela (2013), pode-se considerar 10 etapas na RSL:

- **Planejamento da pesquisa:** Nesta etapa inicial deve ser analisado qual o prazo o autor possui para finalizar o trabalho, se é interessante o uso de algum sistema específico, o qual será permitido a contribuição de outras pessoas na pesquisa e obtenção de orientação da instituição;
- **Definição da pergunta, escopo de pesquisa e protocolo:** Uma Revisão Sistemática da literatura requer questões bem formuladas assim como qualquer outra investigação científica, tais questões devem ser respondidas pelo estudo feito;
- **Pesquisa na literatura:** Normalmente aplica-se a definição das palavras-chave, tais palavras serão utilizadas para realizar a pesquisa nas fontes de informações que podem ser físicas ou virtuais;
- **Triagem, Estágio 1:** Na triagem de Estágio 1, é realizada a leitura dos títulos, resumos (*abstract*) e removidos os resultados duplicados;
- **Obtenção dos papéis:** Após a triagem de Estágio 1, os estudos não removidos serão obtidos em seu formato completo;
- **Triagem, Estágio 2:** Critérios rigorosos serão aplicados para garantir que os estudos selecionados possuem as principais informações que necessita, nesta etapa é realizada a leitura completa;

- **Avaliação de qualidade:** Análise individual de cada estudo selecionado após o Estágio 2;
- **Extração de dados:** Identifique quais serão os campos pertinentes e elabore sua tabela com dados relevantes dos estudos selecionados;
- **Síntese das evidências:** Utilize técnicas para combinação de dados para permitir uma análise mais eficiente; e
- **Apresentação dos resultados:** Destaca-se as características apresentando os resultados obtidos que respondem ao propósito do estudo.

Segundo [Boland Angela \(2013\)](#) a RSL é uma boa maneira para a investigação das evidências científicas, pois apresenta de forma objetiva e fácil os resultados.

Nas próximas seções deste capítulo são apresentadas as etapas da pesquisa, dividida em: elaboração da pergunta, quais foram as bases científicas utilizadas, métodos de pesquisa e por fim, a triagem e avaliação dos resultados.

3.2.1 Bases de Dados Científicas utilizadas

Para a realização das pesquisas presentes nesta RSL, foram utilizadas plataformas conveniadas com a UNESP que puderam ser acessadas através de conexão na Rede Privada Virtual (VPN) da instituição. As bases de dados científicas utilizadas foram Associação para Máquinas de Computação (ACM), Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE).

A Biblioteca Digital ACM é uma plataforma de pesquisa e descoberta que contém a coleção de texto completo de todas as publicações da ACM, incluindo periódicos, anais de conferências, revistas técnicas, boletins informativos e livros, além de contar com uma coleção de publicações hospedadas de editores selecionados ([ACM, 2022](#)).

O Portal de Periódicos CAPES é um dos maiores acervos científicos virtuais do país, que reúne e disponibiliza conteúdos produzidos nacionalmente e outros assinados com editoras internacionais a instituições de ensino e pesquisa no Brasil. São mais de 49 mil periódicos com texto completo e 455 bases de dados de conteúdos diversos, como referências, patentes, estatísticas, material audiovisual, normas técnicas, teses, dissertações, livros e obras de referência ([CAPES, 2022](#)).

O IEEE *Xplore* é uma poderosa base de dados digital para pesquisa e descoberta de estudos científicos relacionados a engenharia eletrônica, computação e áreas correlacionadas. Aproximadamente 25 mil documentos são adicionados por mês neste repositório. O conteúdo do IEEE *Xplore* compreende mais de 260 periódicos, mais de 4 milhões de documentos de

conferências, centenas de horas de cursos, mais de 6 mil livros e mais de 12 mil padrões técnicos ([IEEE, 2022](#)).

3.2.2 Objetivos

O objetivo desta RSL é a identificação de estudos relevantes que compreendam a classificação de movimentos e como a Visão Computacional e IA podem contribuir para isto e como o XAI pode auxiliar na explicação do resultado.

3.2.3 Questões de pesquisa

Após análises e pesquisas prévias, chegou-se à seguinte pergunta principal para a pesquisa:

Como a Visão Computacional e IA podem contribuir para a classificação de movimentos de pacientes pós-AVC e como XAI pode ajudar a compreender as decisões tomadas pela IA?

Esta pergunta principal pode ser expandida nas seguintes questões:

- Qual a autoria do *dataset*?
- Quais os tipos de captura do *dataset*?
- Quais foram os *datasets* utilizados?
- Quais foram as linguagens de programação utilizadas?
- Quais foram as abordagens de IA aplicadas?
- Como XAI está sendo aplicado à explicação da classificação de movimentos?

3.2.4 Critérios de inclusão e exclusão

Nesta etapa foram definidos os critérios de avaliação dos estudos para avaliar quais estudos avançam para a próxima etapa da revisão.

Para a exclusão foram utilizados os seguintes critérios:

- Ter mais de 5 anos, então considerando que a pesquisa foi realizada no ano de 2022, foi realizado um filtro para buscar apenas estudos lançados a partir de 2017;
- Artigo duplicado;
- Não ser do idioma inglês ou português;
- Não apresentar a resposta de pelo menos uma das questões definidas; e
- Não ter afinidade com a proposta desta dissertação.

Já para a inclusão foram considerados tais critérios:

- Ter afinidade com a proposta desta dissertação; e
- Responder ao menos uma das questões definidas.

3.2.5 Métodos de pesquisa

Com a definição das perguntas a serem respondidas, critérios de inclusão e exclusão definidos e com as bases de dados científicos selecionadas, foram elaboradas estruturas de pesquisas com o propósito de encontrar estudos relacionados nas três bases de dados científicos escolhidas: ACM, IEEE e Portal Capes. Durante as pesquisas já foram considerados os seguintes critérios de exclusão: "Ter mais de cinco anos, então considerando que a pesquisa foi realizada no ano de 2022, foi realizado um filtro para buscar apenas estudos lançados a partir de 2017" e "Não ser do idioma inglês ou português".

A primeira *string* de pesquisa foi aplicada durante o período de 07/04/2022 até 17/04/2022 e é exibida na Tabela 1:

Tabela 1 – Primeira *string* de pesquisa.

PALAVRAS-CHAVE	ESTRUTURA
artificial intelligence, xai, artificial intelligence explainable, stroke e rehabilitation	("artificial intelligence" OR xai OR "artificial intelligence explainable") AND (stroke OR rehabilitation)

Fonte: Produzido pelo autor.

O resultado da primeira *string* de pesquisa não foi satisfatório pois a maior parte dos resultados pertenciam a temas que não são de interesse deste trabalho, logo foi aplicado uma segunda *string* de pesquisa nas bases de dados selecionadas. A segunda *string* de busca pesquisa foi utilizada no período de 18/04/2022 até 23/04/2022, tal *string* de pesquisa é mencionada na Tabela 2:

Tabela 2 – Segunda *string* de pesquisa utilizada.

PALAVRAS-CHAVE	ESTRUTURA
deep learning, xai, artificial intelligence explainable, computer vision, classification techniques e evaluation	("deep learning" OR xai OR "artificial intelligence explainable") AND "computer vision" AND ("classification techniques" OR evaluation OR stroke)

Fonte: Produzido pelo autor.

Um problema encontrado na *string* de pesquisa foi a falta de resultados específicos sobre XAI, logo uma terceira *string* de pesquisa foi criada, onde um operador lógico OR

foi adicionado para enriquecer o resultado com estudos sobre XAI. A *string* de pesquisa é exibida na Tabela 3, esta versão foi utilizada em 24/04/2022.

Tabela 3 – Terceira *string* de pesquisa utilizada.

PALAVRAS-CHAVE	ESTRUTURA
deep learning, xai, artificial intelligence explainable, computer vision, classification techniques, evaluation e xai methods	("deep learning"OR xai OR "artificial intelligence explainable") AND "computer vision"AND ("classification techniques"OR evaluation OR stroke) OR xai methods

Fonte: Produzido pelo autor.

Considerando apenas estudos publicados a partir de 01/01/2017, aplicados ao filtro descrito na Tabela 3, foram obtidos 560 trabalhos, a quantia de estudos pela base dados a qual foram originados é listado na Tabela 4.

Tabela 4 – Quantidade de documentos retornados por bases científicas.

Base científica	Documentos selecionados
ACM	48
Capes	239
IEEE	273
TOTAL	560


Fonte: Produzido pelo autor.

3.2.6 Triagem e avaliação dos artigos

O processo de triagem e avaliação foi dividido em diferentes estágios que são discutidas nesta seção. A cada estágio eram aplicados filtros conforme os critérios de inclusão e exclusão estabelecidos.

A Figura 4 ilustra o fluxo que foi aplicado.

Figura 4 – Fluxo de triagem.



Fonte - Autor

Devido ter sido utilizado uma ferramenta de planilhas eletrônicas, foi criado um código sequencial para cada artigo com o intuito de facilitar a gestão do material, com isso foram gerados códigos entre 1 e 560.

No primeiro filtro, o critério de exclusão aplicado foi a remoção dos artigos duplicados, foram removidos 22 artigos aplicando tal critério. Na sequência foi realizada a leitura dos *abstracts* para a aplicação segundo filtro, que levou em consideração o seguinte critério de exclusão "Não ter afinidade com a proposta desta dissertação".


Após a leitura dos *abstracts* dos 538 artigos, foram removidos 494 artigos, com esta triagem dos *abstracts* o total atualizado passou para 44 artigos, esta etapa da triagem foi a responsável pela maior quantia de remoção de estudos.

Por fim, o terceiro filtro da triagem consistiu na leitura total dos 44 artigos restantes e nela foram aplicados os seguintes critérios de exclusão "Não apresentar a resposta de pelo menos uma das questões definidas" e "Não ter afinidade com a proposta desta dissertação", nesta etapa final também foram aplicados os critérios de inclusão. Conforme cada artigo era lido neste processo, a planilha era preenchida para que os critérios fossem analisados nesta RSL. Após a leitura completa 18 artigos foram removidos, com isso, a base de estudos aprovados para esta RSL ficou com 26 trabalhos.

A Figura 5 ilustra o percentual de trabalhos aprovados e os reprovados por etapa

de triagem. Dentre as fases de reprovação, é exemplificado que a maior parte ocorreu na leitura dos *abstracts*, correspondendo a 88,21% (494 artigos) do total dos estudos, outro dado relevante, é que 4,64% (26 artigos) dos estudos foram considerados aceitáveis para esta RSL.

Figura 5 – Trabalhos aprovados e os reprovados por etapa de triagem.



Fonte - Autor

Segue na Tabela 5, a quantia de artigos aprovados conforme a base de dados científica, nesta tabela é exemplificado que a base de dados com a maior quantia de artigos aprovados para esta RSL foi a IEEE com 13 artigos, seguido pelo Portal Capes com 9 estudos e por fim a ACM com 4 trabalhos.

Tabela 5 – Quantidade de documentos aprovados por bases científicas.


Base científica	Documentos selecionados
ACM	4
Capes	9
IEEE	13
TOTAL	26

Fonte: Produzido pelo autor.

A Figura 6 ilustra a divisão de artigos aprovados por ano de publicação do estudo, notamos que 20 dos 26 selecionados são trabalhos mais recentes, ou seja, 2020 e 2021, isso corresponde a quase 77% do total.

Considerando em ordem decrescente de anos com maior quantia de trabalhos publicados que foram considerados nesta RSL temos: 1º 2020 e 2021 com 10 artigos cada, 3º 2019 com 3 artigos seguido por 2018 com 2 artigos e por último está o ano de 2017 com 1 artigo.

Figura 6 – Trabalhos aprovados conforme ano de publicação.



Fonte - Autor

A lista dos trabalhos selecionados para esta RSL é exibida na Tabela 6, que inclui autores, ano de publicação (juntamente com a citação dos autores), nome do artigo e a

base de dados científica. Os dados da Tabela 6 estão ordenados decrescentemente por ano e ascendente por nome dos autores. Logo após a Tabela 6, este trabalho apresenta Seção 3.6 contendo quais foram os dados extraídos com a pesquisa e a leitura dos estudos.

Tabela 6 – Lista de documentos aprovados.

Autores	Estudo	Base
Park et al. (2021)	A Body Part Embedding Model With Datasets for Measuring 2D Human Motion Similarity	Capes
Rupprechter et al. (2021)	A Clinically Interpretable Computer-Vision Based Method for Quantifying Gait in Parkinson’s Disease	Capes
Ullah et al. (2021)	Analysis of Deep Neural Networks for Human Activity Recognition in Videos—A Systematic Literature Review	IEEE
Du et al. (2021)	Assessing Physical Rehabilitation Exercises using Graph Convolutional Network with Self-supervised regularization	IEEE
F e Singh (2021)	Computer Vision-based Survey on Human Activity Recognition System Challenges and Applications	IEEE
Fiorini et al. (2021)	Daily Gesture Recognition During Human-Robot Interaction Combining Vision and Wearable Systems	Capes
Al-Wesabi et al. (2021)	Design of Optimal Deep Learning Based Human Activity Recognition on Sensor Enabled Internet of Things Environment	IEEE
Slijepcevic et al. (2021)	Explaining Machine Learning Models for Clinical Gait Analysis	ACM
Sheth et al. (2021)	Knowledge-Intensive Language Understanding for Explainable AI	IEEE
Tang et al. (2021)	Layer-Wise Training Convolutional Neural Networks With Smaller Filters for Human Activity Recognition Using Wearable Sensors	Capes
Šimić, Sabol e Veas (2021)	XAI Methods for Neural Time Series Classification: A Brief Review	Capes
Zhang et al. (2020)	An Augmented Treble Stream Deep Neural Network for Video Analysis	IEEE
Yilmaz et al. (2020)	A Novel Action Recognition Framework Based on Deep-Learning and Genetic Algorithms	Capes
Continua na próxima página		

Fonte: Produzido pelo autor.

Tabela 6 – Lista de documentos aprovados - continuação.

Autores	Estudo	Base
Al-Faris et al. (2020)	A Review on Computer Vision-Based Methods for Human Action Recognition	Capes
Murray, Stankovic e Stankovic (2020)	Explainable NILM Networks	ACM
Abdelbaky e Aly (2020)	Human Action Recognition based on Simple Deep Convolution Network PCA-Net	IEEE
Tang (2020)	Hybridized Hierarchical Deep Convolutional Neural Network for Sports Rehabilitation Exercises	IEEE
Kim e Lee (2020a)	Lightweight Stacked Hourglass Network for Human Pose Estimation	Capes
Moro et al. (2020)	Markerless Gait Analysis in Stroke Survivors Based on Computer Vision and Deep Learning: A Pilot Study	ACM
Kim e Lee (2020b)	MultiD-CNN: A multi-dimensional feature learning approach based on deep convolutional networks for gesture recognition in RGB-D image sequences	Capes
Baur et al. (2019)	I see what you did there: Understanding when to trust a ML model with NOVA	IEEE
Boualia e Amara (2019)	Pose-based Human Activity Recognition: a review	IEEE
Schlegel et al. (2019)	Towards A Rigorous Evaluation Of XAI Methods On Time Series	IEEE
Jogin et al. (2018)	Feature Extraction using Convolution Neural Networks (CNN) and Deep Learning	IEEE
Xie, Li e Harland (2018)	Movement and Gesture Recognition Using Deep Learning and Wearable-Sensor Technology	ACM
Gammulle et al. (2017)	Two Stream LSTM: A Deep Fusion Framework for Human Action Recognition	IEEE

Fonte: Produzido pelo autor.

3.2.7 Dados Extraídos

Com a leitura dos estudos selecionados, foram extraídos dados do conteúdo, onde no total formou-se uma base de dados para compor o resultado. A base de dados criada com a RSL possui as seguintes colunas:

- Título do artigo;
- Nome dos autores;

- Ano de publicação;
- Base de dados científico;
- Autoria do *dataset*;
- Tipo de captura para o *dataset*;
- Quais foram os *datasets*;
- Tecnologia utilizada;
- Abordagem de IA aplicadas; e
- Como XAI está sendo aplicado à explicação da classificação de movimentos.

Conforme exibido nesta seção, a pesquisa e RSL utilizando bases de dados científicos se mostrou importante para o trabalho, pois por meio de sua metodologia foi capaz de selecionar 26 artigos relevantes para esta dissertação. Pode-se também notar o aumento no número de estudos nos últimos anos, onde em 2020 e 2021 se concentraram a maior parte dos estudos selecionados (77,6%).

3.3 Análise e Discussão dos Resultados

O objetivo desta seção é apresentar os resultados obtidos com a leitura dos 26 artigos selecionados por meio da RSL, os resultados são divididos em seções conforme as questões:

- Q1 Qual a autoria do *dataset*;
- Q2 Quais os tipos de captura do *dataset*;
- Q3 Quais foram os *datasets* utilizados;
- Q4 Quais foram as linguagens de programação utilizadas;
- Q5 Quais foram as abordagens de IA aplicadas; e
- Q6 Como XAI está sendo aplicado à explicação da classificação de movimentos.

3.3.1 Q1: Autoria do Dataset

A primeira questão é referente a autoria do *dataset* utilizado pelos pesquisadores, se foram os próprios autores de cada artigo que elaboraram os *datasets* ou se utilizaram *datasets* disponibilizados por outros autores.

A disponibilidade de conjuntos de dados em grande escala para com movimentos é limitada e existem poucos conjuntos de dados de movimento humano disponíveis para avaliar o desempenho de diferentes métodos de computação de similaridade (PARK et al., 2021).


Um problema que encontrado é que se não houver um *dataset* grande disponível para treinamento, o algoritmo de classificação pode ser prejudicado, além das posições chave desempenharem um papel importante (BOUALIA; AMARA, 2019).

Devido tais desafios, podemos entender que a variedade para origem do *dataset* pode ser explicada nesta análise, considerando apenas trabalhos que relataram a origem, os resultados foram classificados em três categorias que são:

- **Próprio:** Os autores coletaram as imagens/vídeos utilizados em suas análises e criaram o próprio *dataset*;
- **Terceiros:** Os autores utilizaram *datasets* construídos por outras pessoas; e
- **Próprio + Terceiros:** Nesta terceira categoria unimos as duas anteriores, ou seja, os autores além de criarem *datasets* utilizaram fontes já disponíveis.

A Figura 7 ilustra a quantia e a porcentagem conforme categorias explicadas.

Figura 7 – Quantia e porcentagem de artigos conforme autoria do dataset.



Analisando a Figura 7, é obtido um argumento que reforça o comentário de [Park et al. \(2021\)](#), pois 80% (16 artigos) dos estudos selecionados utilizaram somente *datasets* de terceiros e outros 15% (3 artigos) tiveram como parte de sua fonte de dados os *datasets* de terceiros, com isso, é entendido que 95% dos artigos utilizaram fontes de dados já disponíveis.

Segue na Tabela 7, a classificação atribuída para cada trabalho conforme a autoria do *dataset*:

Tabela 7 – Lista de documentos conforme autoria do dataset.

Autores	Tipo
Fiorini et al. (2021)	Próprio
Park et al. (2021)	Próprio + Terceiros
Rupprechter et al. (2021)	Próprio + Terceiros
Al-Wesabi et al. (2021)	Próprio + Terceiros
Yilmaz et al. (2020)	Terceiros
Al-Faris et al. (2020)	Terceiros
Zhang et al. (2020)	Terceiros
Ullah et al. (2021)	Terceiros
Du et al. (2021)	Terceiros
Slijepcevic et al. (2021)	Terceiros
Jogin et al. (2018)	Terceiros
Abdelbaky e Aly (2020)	Terceiros
Continua na próxima página	

Fonte: Produzido pelo autor.

Tabela 7 – Lista de documentos conforme autoria do dataset - continuação.

Autores	Tipo
Tang et al. (2021)	Terceiros
Kim e Lee (2020a)	Terceiros
Moro et al. (2020)	Terceiros
Xie, Li e Harland (2018)	Terceiros
Kim e Lee (2020b)	Terceiros
Boualia e Amara (2019)	Terceiros
Schlegel et al. (2019)	Terceiros
Gammulle et al. (2017)	Terceiros

Fonte: Produzido pelo autor.

3.3.2 Q2: Quais os tipos de captura do dataset

Para responder a segunda questão foi analisado nos estudos aprovados, qual foi o mecanismo de captura utilizado nos *datasets* dos trabalhos, o resultado mostra uma divisão entre captura por vídeos e captura por sensores, a qual possuem argumentos diferentes dos autores para serem defendidas.

Segundo [Al-Wesabi et al. \(2021\)](#), a instalação de câmeras invade a privacidade dos participantes, resultando em problemas. Já a presença de sensores está amplamente incorporada em nosso ambiente, podem registrar as atividades de HAR sem atrapalhar a rotina da pessoa. Um exemplo de um sensor é o dispositivo vestível *SensHand*, que é capaz de adquirir dados do dedo indicador e do pulso ([FIORINI et al., 2021](#)).


Entretanto, conforme [Rupprechter et al. \(2021\)](#), menciona que sensores permitem uma caracterização detalhada do movimento, porém são onerosos para os voluntários quanto para os avaliadores, exigindo equipamentos adicionais, tornando o processo mais complexo a agregando custo ao projeto.

Muitas vezes, o uso de sensores em ambientes domésticos se torna impraticável, entretanto já é situação comum os médicos gravarem vídeos durante os exames físicos utilizando equipamentos de câmera disponíveis comercialmente. Avanços recentes em estimativa de pose baseada em Aprendizado Profundo permitem que um sistema obtenha as características a partir de uma gravação de vídeo ([RUPPRECHTER et al., 2021](#)).

Segundo [Moro et al. \(2020\)](#), na literatura de Visão Computacional é possível encontrar métodos para a análise de dados de vídeo que permitem obter estimativas de junções e esqueletos, já tecnologias como câmeras infravermelhas com marcadores no corpo possuem precisão, porém envolvem sistemas caros que não podem ser custeados por muitos clínicos e pesquisadores.

A Figura 8 ilustra os tipos de captura utilizados nos *datasets* dos artigos, é considerado apenas artigos que especificaram a fonte.

Figura 8 – Quantidade de artigos conforme tipo de captura do dataset.



Fonte - Autor

Conforme Figura 8, pode-se notar que a origem por vídeo esteve presente na maior parte (65%) dos artigos que especificaram o *dataset*, seguido pelo uso de sensores que esteve presente em 30% dos estudos.

A Tabela 8 contém a listagem dos artigos que especificaram o *dataset* ou o tipo de captura e sua classificação conforme esta seção.

Tabela 8 – Lista de artigos conforme tipo do dataset.

Autores	Tipo
Park et al. (2021)	Vídeo
Al-Faris et al. (2020)	Vídeo
Zhang et al. (2020)	Vídeo
Ullah et al. (2021)	Vídeo
Du et al. (2021)	Vídeo
Moro et al. (2020)	Vídeo
Abdelbaky e Aly (2020)	Vídeo
Kim e Lee (2020b)	Vídeo
Schlegel et al. (2019)	Vídeo
Gammulle et al. (2017)	Vídeo
Yilmaz et al. (2020)	Vídeo + sensor
Fiorini et al. (2021)	Vídeo + sensor
Continua na próxima página	

Fonte: Produzido pelo autor.

Tabela 8 – Lista de artigos conforme tipo do dataset - continuação.

Autores	Tipo
Rupprechter et al. (2021)	Vídeo
Al-Wesabi et al. (2021)	Sensor
Tang (2020)	Sensor
Tang et al. (2021)	Sensor
Xie, Li e Harland (2018)	Sensor
Slijepcevic et al. (2021)	Imagens
Jogin et al. (2018)	Imagens
Kim e Lee (2020a)	Imagens

Fonte: Produzido pelo autor.

3.3.3 Q3: Quais foram os datasets utilizados

Esta terceira questão refere-se à quais foram os *datasets* utilizados pelos pesquisadores em seus trabalhos, para responder esta pergunta será apresentado por autor quais foram as fontes utilizadas.

Dentre os *datasets* utilizados, o UI-PRMD é um *dataset* de movimentos relacionados a exercícios comuns realizados por pacientes em programas de fisioterapia e reabilitação, está disponível gratuitamente para todos os usuários interessados ([VAKANSKI D. PAUL, 2018](#)). A Figura 9 ilustra um exemplo do *dataset* UI-PRMD.


Figura 9 – Exemplo do dataset UI-PRMD.



Fonte - ([VAKANSKI D. PAUL, 2018](#))

A Figura 10 ilustra quais foram os grupos dos *datasets* mais utilizados, foram considerados apenas situações em que os *datasets* foram utilizados mais de duas vezes.

Figura 10 – Datasets mais utilizados.



Fonte - Autor

Os *datasets* UCF Sports, UCF11, UCF50 e UCF101 são os quatro *datasets* de ação compilados pela Universidade da Flórida Central. UCF11 possui 11 categorias, já UCF50 é uma extensão de UCF11 e possui 50 categorias e UCF101 é uma extensão de UCF50 e possui 101 categorias, todo seu conteúdo foi extraído do YouTube. Já UCF Sports foi criado por uma equipe de filmagem profissional (SOOMRO; SHAH, 2012).

O KHT é um *dataset* de vídeo contendo 6 tipos de ações humanas (caminhada, trote, corrida, boxe, aceno de mão e palmas) realizadas várias vezes por 25 sujeitos em quatro cenários diferentes, as sequências possuem duração média de 4 segundos (LAPTEV, 2005).

O *dataset* HMDB foi coletado de várias fontes, principalmente de filmes, e uma pequena proporção de bancos de dados públicos, como o arquivo Prelinger, YouTube e vídeos do Google. O *dataset* contém 6.849 clipes divididos em categorias, dentre elas há categorias específicas para o movimento do corpo humano (KUEHNE et al., 2011).

A Tabela 9 lista os artigos que especificaram quais *datasets* utilizaram e quais foram.

Tabela 9 – Lista de artigos conforme datasets.

Autores	Datasets
Slijepcevic et al. (2021)	GaitRec SPM1D2
Moro et al. (2020)	Dados da Recuperação e Unidade de Re- educação Funcional do Hospital Santa Corona
Xie, Li e Harland (2018)	HCL Ninapro
Park et al. (2021)	NTU RGB+D
Yilmaz et al. (2020)	KTH Skoda UCF UCI
Tang et al. (2021)	OPPORTUNITY PAMAP2 UNIMIB-SHAR WISDM
Rupprechter et al. (2021)	MDS Video Library
Al-Wesabi et al. (2021)	UCI (Har)
Du et al. (2021)	UI-PRMD
Jogin et al. (2018)	CIFAR-10
Abdelbaky e Aly (2020)	KTH
Al-Faris et al. (2020)	Berkeley-MHAD HMDB51 Hollywood2 KTH MSR Northwestern-UCLA NTU RGB+D Olympic Sports RGBD-HuDaAct UCF UTD-MHAD Weizmann
Schlegel et al. (2019)	ChlorineConcentration Earthquakes Elec tricDevices Ford (A e B) MelbournePedestrian NonInvasive FetalECGThorax Physionet’s MIT BIH Arrhythmia Strawberry
Gammulle et al. (2017)	jHMDB UCF

Continua na próxima página

Fonte: Produzido pelo autor.

Tabela 9 – Lista de artigos conforme datasets - continuação.

Autores	Tipo
Zhang et al. (2020)	HMDB51 UCF
Ullah et al. (2021)	Behave CAD DML SmartActions HMDB51 Hollywood2 jHMDB Kinects KTH KU MPII UCF UTD-MHAD Volleyball Weizmann YouTube
Kim e Lee (2020b)	IsoGD NATOPS SBU SKIG

Fonte: Produzido pelo autor.

3.3.4 Q4: Quais foram as linguagens de programação utilizadas

As linguagens de programação utilizadas nos estudos é discutida nesta seção, assim como o Python os estudos demonstraram também que o MATLAB foi utilizado.

O MATLAB é um programa de computador de uso específico otimizado para executar cálculos, este programa implementa a linguagem MATLAB e oferece ampla biblioteca de funções pré-definidas para que a programação se torne mais fácil e eficiente ([CHAPMAN, 2003](#)).

Dentre os estudos que relataram o uso do Python, foi constatado que algumas bibliotecas foram mais utilizadas, dentre as mais citadas temos o OpenPose, PyTorch e o TensorFlow.

O OpenPose foi utilizado por [Rupprechter et al. \(2021\)](#) e [Fiorini et al. \(2021\)](#), é uma biblioteca de código aberto desenvolvida na Carnegie Mellon University em 2017, alcançou grande interesse pelos pesquisadores devido ao seu desempenho computacional para extração de articulações do corpo. O OpenPose pode operar em tempo real detectando expressões faciais, articulações do corpo e das mãos ([NOORI; WALLACE BENEDIKTEAND UDDIN, 2019](#)).


Já utilizado por [Zhang et al. \(2020\)](#) e [Du et al. \(2021\)](#), o PyTorch é uma biblioteca para Python que contribui para o desenvolvimento de aplicações com Aprendizado Profundo.

Tem um escopo expansivo e é aplicado para várias cenários (IMAMBI; PRAKASH; KANAGACHIDAMBARESAN, 2021).

O TensorFlow é uma biblioteca de software flexível e escalável para cálculos numéricos usando gráficos de fluxo de dados. Essa biblioteca e as ferramentas relacionadas permitem que os usuários programem e treinem com eficiência a rede neural e outros modelos de Aprendizado de Máquina (PANG; NIJKAMP; WU, 2020). O TensorFlow foi utilizado por Xie, Li e Harland (2018) e Rupprechter et al. (2021) (que também utilizou OpenCv e Scikit-Learn).

É ilustrado na Figura 11, a quantia e percentual dos trabalhos e quais foram as linguagens utilizadas, para esta análise foi considerado apenas estudos que relataram a linguagem utilizada.

Figura 11 – Linguagens utilizadas nos trabalhos.



Fonte - Autor

Conforme Figura 11 que considera apenas estudos que informaram a linguagem de programação utilizada, é constatado que linguagem mais aplicada foi Python, 80% (8 artigos) utilizaram somente Python e outros 10% (1 artigo) utilizou Python e Matlab, totalizando a presença do Python em 90% dos estudos que mencionaram a linguagem de programação. Já o Matlab foi a única linguagem de programação em 10% dos estudos, considerando que Matlab esteve presente juntamente com Python em outros 10% pode-se considerar que a linguagem Matlab foi utilizada em 20% dos artigos que informaram a linguagem de programação aplicada.

A Tabela 10 exibe a lista de artigos que informaram as linguagens de programação que utilizaram.

Tabela 10 – Lista de artigos conforme linguagem de programação.

Autores	Linguagem de programação
Al-Wesabi et al. (2021)	Python
Yilmaz et al. (2020)	Python
Zhang et al. (2020)	Python
Du et al. (2021)	Python
Fiorini et al. (2021)	Python
Tang et al. (2021)	Python
Kim e Lee (2020a)	Python
Xie, Li e Harland (2018)	Python
Slijepcevic et al. (2021)	Python + Matlab
Moro et al. (2020)	Matlab

Fonte: Produzido pelo autor.

3.3.5 Q:5 Quais foram as abordagens de IA aplicadas

Esta seção tem o objetivo de apresentar quais foram as abordagens de IA aplicadas pelos autores.

Segundo [Ullah et al. \(2021\)](#), estudos anteriores em sistemas HAR consideram o reconhecimento de atividade como um problema típico de identificação de padrões. Com a evolução do Aprendizado Profundo, as aproximações artesanais são substituídas, pois o Aprendizado Profundo permite a extração direta de recursos dos dados, portanto, não requer nenhum conhecimento especializado ou seleção de recursos ideais.

A afirmação de [Ullah et al. \(2021\)](#) é reforçada por [Tang et al. \(2021\)](#), o autor cita que HAR pode ser considerado um problema típico de reconhecimento de padrões, e as abordagens tradicionais de Aprendizado de Máquina fizeram grandes conquistas na área, porém, as abordagens convencionais podem depender fortemente da extração de recursos artesanais, que necessita experiência especializada ou conhecimento de domínio. Nos últimos anos, o Aprendizado Profundo representa a maior tendência no campo de Aprendizado de Máquina.


Segundo [Xie, Li e Harland \(2018\)](#) a tecnologia Aprendizado Profundo possibilita que computadores por meio de IA colem dados, analisem dados, classifiquem dados e o resultado sem extração de recursos de forma artesanal. A alta precisão e confiabilidade de modelos de Aprendizado Profundo são comprovadas especialmente nas áreas de reconhecimento de imagens, reconhecimento de sinais e classificação de atividades, isso é vantagem em relação aos modelos convencionais, que sempre custam um longo período de tempo para extrair um conjunto de recursos confiáveis, especialmente para dados de alta dimensão e complexos, além de necessitarem de um conhecimento de domínio de alto nível para a extração de recursos.

Conforme citado pelos autores, o Aprendizado Profundo está cada vez mais em uso para o reconhecimento das ações devido não ser necessário a extração artesanal de recursos

e não necessitar de tanto conhecimento especializado.

Conforme ilustrado na Figura 12, o Aprendizado Profundo foi abordado na maior parte dos artigos, 19 artigos o que corresponde a 73% trabalharam somente com o Aprendizado Profundo e 5 artigos (19%) mencionaram o Aprendizado Profundo juntamente com o Aprendizado de Máquina, isso resulta em 24 artigos de um total de 26 (92%). Já o Aprendizado de Máquina esteve sozinho em 2 artigos (7%) e assim como já mencionado, em 5 artigos estiveram presentes as duas abordagens (19%), totalizando assim presença em 26% dos artigos. A Tabela 11 exibe os autores e as abordagens utilizadas.

Figura 12 – Abordagens utilizadas nos trabalhos.



Fonte - Autor

Tabela 11 – Lista de artigos conforme abordagem.

Autores	Abordagens
F e Singh (2021)	Aprendizado Profundo
Al-Wesabi et al. (2021)	Aprendizado Profundo
Murray, Stankovic e Stankovic (2020)	Aprendizado Profundo
Sheth et al. (2021)	Aprendizado Profundo
Moro et al. (2020)	Aprendizado Profundo
Park et al. (2021)	Aprendizado Profundo
Yilmaz et al. (2020)	Aprendizado Profundo
Zhang et al. (2020)	Aprendizado Profundo
Ullah et al. (2021)	Aprendizado Profundo
Du et al. (2021)	Aprendizado Profundo
Jogin et al. (2018)	Aprendizado Profundo
Tang (2020)	Aprendizado Profundo
Tang et al. (2021)	Aprendizado Profundo
Kim e Lee (2020a)	Aprendizado Profundo
Xie, Li e Harland (2018)	Aprendizado Profundo
Kim e Lee (2020b)	Aprendizado Profundo
Schlegel et al. (2019)	Aprendizado Profundo
Gammulle et al. (2017)	Aprendizado Profundo
Šimić, Sabol e Veas (2021)	Aprendizado Profundo
Al-Faris et al. (2020)	Ambas
Fiorini et al. (2021)	Ambas
Slijepcevic et al. (2021)	Ambas
Abdelbaky e Aly (2020)	Ambas
Boualia e Amara (2019)	Ambas
Rupprechter et al. (2021)	Aprendizado de Máquina
Baur et al. (2019)	Aprendizado de Máquina

Fonte: Produzido pelo autor.

3.3.6 Q6: Como XAI está sendo aplicado à explicação da classificação de movimentos

A última questão desta RSL tem o objetivo de discutir sobre a maneira que os artigos selecionados informam como XAI está sendo utilizado na classificação de movimentos.

O estudo de [Slijepcevic et al. \(2021\)](#) apresenta a utilidade de métodos para aumentar a transparência na classificação clínica automatizada da marcha. A análise da marcha se concentra na descrição quantitativa e análise da marcha humana de um ponto de vista cinemático (ângulos articulares), cinético (forças de reação do solo e momentos articulares) e muscular. Nos últimos anos, métodos de Aprendizado de Máquina têm sido empregados com sucesso na análise da marcha para a classificação de grupos de pacientes, como AVC (dentre outros) e pacientes que sofrem de diferentes distúrbios funcionais da marcha ([SLIJEPCEVIC et al., 2021](#)).

Como resultado, [Slijepcevic et al. \(2021\)](#) informa que métodos XAI podem ajudar a tornar os processos de previsão compreensíveis para especialistas clínicos, facilitando a aplicação de sistemas de apoio à decisão baseados em Aprendizado de Máquina na prática

clínica.

3.3.7 Tendências

Algumas tendências puderam ser constatadas com base no resultado da RSL:

- *Autoria do dataset*: os estudos, em sua grande maioria, abordaram situações em que os *datasets* utilizados não foi de autoria própria mas sim de autoria de um terceiro. Um argumento que reforça este tese é a que disponibilidade de conjuntos de dados em grande escala para trabalhar com movimentos é limitada e existem poucos conjuntos de dados de movimento humano disponíveis (PARK et al., 2021) e um problema que encontrado é que se não houver um *dataset* grande disponível para treinamento, o algoritmo de classificação pode ser prejudicado (BOUALIA; AMARA, 2019).
- *Tipos de captura dos datasets*: nota-se uma tendência na utilização do recurso de vídeo para utilização nos *Datasets*, um fator que pode colaborar com esta tendência é que a utilização de vídeo pode ter o custo considerado mais acessível e a utilização de vídeo já faz parte da rotina de médicos.
- *Datasets* mais utilizados: percebe-se que diferentes *datasets* foram utilizados nos estudos e não notou-se uma diferença grande indicado que um *dataset* fez parte da maioria dos estudos, com isso nota-se que foi adotada uma variedade de *datasets*.
- *Linguagens de programação utilizadas*: percebe-se a tendência de uso da linguagem Python, esta linguagem de programação foi relatada na maior parte dos estudos que especificaram este item. Nota-se também que juntamente ao uso do Python tem-se o uso de algumas bibliotecas como OpenCV, OpenPose, TensorFlow e PyTorch.
- *Abordagens de IA aplicadas*: os estudos, em maior quantia abordaram que o uso do Aprendizado Profundo em relação ao Aprendizado de Máquina, alguns autores relataram que o Aprendizado Profundo está cada vez mais em uso para o reconhecimento das ações devido não ser necessário a extração artesanal de recursos e não necessitar de tanto conhecimento especializado.

3.3.8 Combinações do Artigos Seleccionados

A extração de informações sobre artigos resultou diversas combinações entre autoria do *dataset*, tipos de captura, linguagens de programação e abordagens de IA utilizados no estudos seleccionados na RSL.

A Tabela 12 ilustra tais combinações por artigo.

Tabela 12 – Combinações de artigos seleccionados

Autoria Data Set			Tipos de Captura				Linguagens de programação			Abordagens de IA			Origem
Próprio	Terceiro	Próprio + Terceiro	Imagem	Vídeo	Sensor	Vídeo + Sensor	Python	Matlab	Python + Matlab	Aprendizando profundo	Aprendizando de máquina	Aprendizado profundo + Aprendizado de máquina	
													Abdelbaky e Aly (2020)
													Al-Faris et al. (2020)
													Al-Wesabi et al. (2021)
													Baur et al. (2019)
													Boualia e Amara (2019)
													Du et al. (2021)
													F e Singh (2021)
													Fiorini et al. (2021)
													Gammulle et al. (2017)
													Jogin et al. (2018)
													Kim e Lee (2020a)
													Kim e Lee (2020b)
													Moro et al. (2020)
													Murray, Stankovic e Stankovic (2020)
													Park et al. (2021)
													Rupprechter et al. (2021)
													Schlegel et al. (2019)
													Sheth et al. (2021)
													Šimić, Sabot e Veas (2021)
													Sljepcevic et al. (2021)
													Tang (2020)
													Tang et al. (2021)
													Ullah et al. (2021)
													Xie, Li e Harland (2018)
													Yilmaz et al. (2020)
													Zhang et al. (2020)

Fonte: Produzido pelo autor.

Com as combinações extraídas, é possível posicionar novos trabalhos de acordo com a literatura existente e identificar situações pouco exploradas, que possam combinar atributos considerados pouco utilizados e até mesmo atributos comuns.

3.3.9 Considerações Finais do Capítulo

Este capítulo apresentou as análises realizadas com base na RSL que foi elaborada a partir das questões definidas. A busca foi realizada em 3 bases científicas que retornaram 560 artigos e com a aplicação do fluxo de triagem o número de artigos foi reduzido para 26.

Com base nos resultados foi possível notar que a maior parte dos autores utilizam *datasets* já prontos e é visto com maior frequência que tais *datasets* utilizaram a captura por câmera, dentre os *datasets* utilizados foi encontrado um próprio para movimentos de reabilitação. Foi avaliado que a maior parte dos autores utilizaram a linguagem de programação Python. Como abordagem de IA o Aprendizado Profundo foi encontrado na maior parte dos trabalhos.

Os resultados obtidos pela RSL mostraram tendências que podem ser exploradas para contribuir para a área de reabilitação com uso de Visão Computacional e IA, tais tendências podem contribuir com trabalhos futuros, bem como a especificação presente no Capítulo 4.

4 ESPECIFICAÇÃO DA SOLUÇÃO

4.1 Considerações Iniciais do Capítulo

O presente capítulo tem como objetivo mostrar o cenário em que o problema está inserido, quais foram os requisitos e funcionalidades da aplicação desenvolvida e como as tendências verificadas na RSL foram aplicadas na solução do problema.

4.2 Cenário

Cada vez mais as áreas de Computação e Saúde trabalham de forma cooperada para atingirem melhores resultados, na área de Computação podemos destacar a Visão Computacional como uma grande aliada da Saúde pois diversos projetos foram desenvolvidos neste segmento.

Esta dissertação cujo nome é "Uma Combinação da Visão Computacional e Inteligência Artificial para Analisar Movimentos em Apoio à Reabilitação de Pacientes Pós Acidente Vascular Cerebral" tem o propósito de apresentar uma aplicação para que profissionais da área de reabilitação motora pós-AVC possam ter uma ferramenta a mais em seu cotidiano, para que esta ferramenta tecnológica possa contribuir com o processo de reabilitação motora dos pacientes.

Através da ferramenta proposta, busca-se que o profissional de reabilitação motora:

- Trabalhe com diversos pacientes;
- Trabalhe com diversos movimentos;
- Parametrize os ângulos dos movimentos a serem analisados;
- Grave as sessões;
- Reproduza as sessões quando necessário;
- Realize a análise de cada seção de forma individual com uma ferramenta gráfica;
- Analise a evolução de cada paciente para cada movimento específico; e
- Possa ter suas sessões integradas em uma ferramenta externa.

A Figura 13 ilustra o diagrama de caso de uso da aplicação.

Figura 13 – Diagrama de caso de uso.



Fonte - Autor

4.3 Requisitos da aplicação

Esta seção apresenta quais são os requisitos e funcionalidades no software desenvolvido que possui como objetivo auxiliar o profissional de saúde responsável pelo processo de reabilitação motora.


4.3.1 Tipo de Captura de Movimentos

De acordo com a RSL, a maioria dos estudos que informaram o tipo para captura utilizado optaram por vídeo. Para este trabalho o tipo de captura escolhida é a captura por vídeo confuncional, fatores que contribuem para esta escolha é que geralmente clínicas de reabilitação já podem possuir computadores com câmeras, a câmera

é um equipamento menos custoso comparada à sensores de movimentos e técnicas de Visão Computacional e IA podem ser utilizadas com apenas a informação de câmeras convencionais.

A Figura 14 ilustra a combinação de Visão Computacional e IA para detectar articulações do corpo humano e listar as coordenadas X e Y de cada membro identificado.

Figura 14 – Combinação de Visão Computacional e IA para detectar articulações do corpo humano.



Fonte - Autor

4.3.2 Hardware para execução

O sistema desenvolvido tem como usuário o profissional de saúde responsável pelo processo de reabilitação motora, muitas das sessões de reabilitação são realizadas em clínicas e geralmente estas clínicas já podem possuir computadores, outro fator que contribuiu para a escolha foi que em comparação à celulares, computadores possuem a tela

maior, com isso sem a aquisição de equipamentos adicionais as sessões são parametrizadas, gravadas e assistidas no mesmo equipamento.

4.3.3 Flexibilidade da solução

A maior parte dos pacientes que sofreram AVC permanecem com alguma sequela, esta sequela pode ser de ordem física e afetar diretamente a mobilidade de distintos membros do corpo humano.

São diversos os recursos eficazes propostos pela fisioterapia na recuperação motora do AVC, as sessões devem sempre respeitar as limitações e serem adaptadas à realidade do paciente (SIQUEIRA PALOMA SCHNEIDERS, 2019), este argumento reforça que durante as sessões de reabilitação diversos movimentos podem ser trabalhados, devido essa diversificação a aplicação conta com uma funcionalidade específica de parametrização de movimentos para que o profissional de saúde responsável pelo processo de reabilitação motora possa trabalhar com diversos exercícios físicos em uma mesma aplicação.

4.3.4 Reprodução das sessões

Outro requisito da aplicação é que todas as sessões possam ser reproduzidas em momentos futuros para que o profissional de saúde responsável pelo processo de reabilitação motora possa assistir e compartilhar com o paciente, demonstrando pontos de acerto, pontos de melhoria e a evolução dos movimentos, esta forma de reprodução usa o recurso de avatar para que não seja armazenado os vídeos das sessões, apenas os pontos corporais dos pacientes são armazenados, além de contribuir com a privacidade do paciente reflete de forma positiva na otimização do banco de dados da aplicação.

4.3.5 Medir o desempenho do paciente

De modo a se obter uma aplicação capaz de auxiliar o profissional de saúde responsável pelo processo de reabilitação motora, um dos requisitos é que a aplicação permita de forma simples que a evolução dos paciente durante as sessões possam ser representada pela aplicação de forma intuitiva. A aplicação além de armazenar os pontos corporais, armazenará também os ângulos gerados durante as sessões pelos movimentos parametrizados, tais ângulos serão a base para representar de forma gráfica um resumo de uma sessão específica e também a comparação entre diversas sessões do mesmo movimento do mesmo paciente ordenado de forma cronológica.

4.3.6 Integração com base de dados externa

Com o intuito de contribuir com a continuidade desta aplicação em estudos futuros, um dos requisitos desta aplicação é que os dados gerados durante uso possam ser integrados

à uma base de dados externa específica de movimentos de reabilitação em que diversas aplicações registram seus resultados.

4.4 Tecnologias Escolhidas

Nesta seção são introduzidas as principais tecnologias escolhidas para desenvolvimento da aplicação.

4.4.1 Python

O Python é uma linguagem de programação simples porém muito poderosa, pode ser utilizada para administrar sistemas e desenvolver grandes projetos. É uma linguagem livre devido o trabalho da *Python Foundation* e de diversos colaboradores ([MENEZES, 2010](#)), o Python foi utilizado em 90% dos estudos que detalharam a linguagem de programação utilizada na RSL desta dissertação.

A *Python Foundation* é uma corporação sem fins lucrativos que detém os direitos de propriedade intelectual da linguagem Python, esta fundação gerencia o licenciamento do código aberto para Python desde a versão 2.1 além de financiar desenvolvimentos relacionados ao Python e projetos especiais com do seu programa de subsídios ([FOUNDATION, 2022](#)).

Segundo [Foundation \(2022\)](#) o Python pode ser utilizado em qualquer arquitetura de computadores, como Linux, FreeBSD, Microsoft Windows ou Mac OS X, esta linguagem vem crescendo em várias áreas, dentre elas a IA.

4.4.2 PyCharm


A linguagem utilizado foi Python e como consequência adotou-se o ambiente de desenvolvimento integrado (IDE) PyCharm.

O PyCharm é uma IDE para programação em Python desenvolvido pela empresa JetBrains que foi fundada em 2000 e possui mais de 115 prêmios conquistados ([JETBRAINS, 2023](#)).

Segundo os resultados da pesquisa de 2021 para desenvolvedores Python, o PyCharm é a IDE utilizada por 31% dos dos 23.000 entrevistados, ficando em segundo lugar, atrás apenas do VS Code da Microsoft com 35% dos votos ([JETBRAINS, 2022](#)).

A Figura 15 ilustra a IDE PyCharm.

Figura 15 – IDE PyCharm



Fonte - Autor

4.4.3 OpenCV

O OpenCV é uma biblioteca de Visão Computacional e Aprendizado de Máquina com código aberto e é licenciado Apache 2. Esta biblioteca possui mais de 2.500 algoritmos otimizados que podem ser utilizados para detectar e reconhecer rostos, classificar ações humanas em vídeos dentre outras funções. Atualmente o OpenCV possui mais de 47 milhões de usuários e é amplamente utilizado em grupos de pesquisas, órgãos governamentais e empresas. Grandes corporações mundiais como Google, Yahoo, Microsoft, Intel, IBM, Sony, Honda, Toyota utilizam a biblioteca. O OpenCV pode ser utilizado com as seguintes linguagens: C++, Python, Java e MATLAB, e suporta os seguintes sistemas operacionais: Windows, Linux, Android e MacOS ([OPENCV, 2023](#)).

A Figura 16 ilustra um polígono da cor azul construído em uma imagem utilizando a biblioteca OpenCV.

Figura 16 – Polígono construído com OpenCV



Fonte - Autor

4.4.4 MediaPipe

Para a detecção de pontos corporais foi utilizado o framework de IA MediaPipe, devido a utilização deste framework completo não foi necessário que para esta aplicação fosse treinada um novo modelo IA para detectar os pontos corporais, atualmente sem um framework como o MediaPipe haveria mais desafios para este trabalho, como aplicar técnicas de Aprendizado de Máquina ou Aprendizado Profundo com base em um *dataset* robusto e construir uma série de protótipos, o uso do MediaPipe trouxe grande agilidade ao trabalho.

Inicialmente foi utilizado neste trabalho o framework de IA Caffe com um modelo já treinado para detectar pontos corporais em imagens. O Caffe é um framework de Aprendizado Profundo (JIA et al., 2014). Utilizando o Caffe, o tempo de processamento


não foi adequado à proposta do trabalho pois a representação dos pontos corporais quando configurados para terem maior exatidão causavam lentidão na reprodução, com isso o framework foi alterado para o Media Pipe.

O MediaPipe foi projetado para profissionais de Aprendizado de Máquina, incluindo pesquisadores, estudantes e desenvolvedores de software (LUGARESI et al., 2019), dentre seus pacotes, neste trabalho foi utilizado o *Pose Landmarker* que permite detectar pontos de referência de corpos humanos em uma imagem ou vídeo, essas informações podem ser usadas para diversas aplicações, como interação humano-computador, análise de movimento e realidade virtual, o MediaPipe utiliza modelos leves de Aprendizado de Máquina otimizando a aceleração do processamento gráfico (GOOGLE, 2022).

Com a solução de *Pose Landmaker*, podem ser obtidas 33 articulações do corpo humano nas posições x, y e z. Para este trabalho, apenas as posições x e y foram consideradas.

A Figura 17 ilustra a detecção de pontos corporais através da biblioteca *Pose Landmaker* do MediaPipe.

Figura 17 – Detecção de pontos corporais




Fonte - Autor

4.4.5 TKinter

Tkinter é uma biblioteca Python que acompanha a instalação padrão e possibilita desenvolver interfaces gráficas (PYTHON.ORG, 2024). O Tkinter foi utilizado neste trabalho devido a praticidade, fácil integração com outros componentes Python e não depender de alto processamento para execução.

Com o Tkinter todos menus e janelas da interface gráfica da aplicação foram construídos, a Figura 18 ilustra um menu e uma janela da aplicação desenvolvidos com o uso da biblioteca Tkinter.

Figura 18 – Interface gráfica construída com Tkinter



Fonte - Autor


4.4.6 SQLite

O SQLite é uma biblioteca implementa um mecanismo de banco de dados SQL transacional independente, sem servidor e sem configuração. O código do SQLite é de domínio público e, portanto, é gratuito para uso para qualquer finalidade, comercial ou privada. O SQLite lê e grava diretamente em arquivos de disco comuns com isso não há a necessidade de uma instalação específica para ele (SQLITE, 2023).

Com tais características, o SQLite não depende de alto poder de processamento para utilização.

A Figura 19 ilustra o resultado de um comando de recuperação de dados no SQLite executado pela ferramenta *DB Browser for SQLite*.

Figura 19 – Recuperação de dados do SQLite




	p1z	p2x	p2y	p2z	p3x	p3y	p3z	p4x	p4y
1	714634895	291.840953350067	157.981729507446	-359.692120313644	296.785936415195	158.281588554382	-359.638970315456	272.213195919991	157.42284059524
2	7887220383	290.275141060352	157.99298286438	-401.150834441185	294.331060945988	158.308041095734	-401.114045619965	269.921836912632	157.4512004852
3	1316723347	286.089094221592	157.822155952454	-344.951811790466	290.332611680031	158.188617229462	-344.966520965099	266.091605961323	157.43858814239
4	1047870636	280.496017932892	157.884156703949	-328.308364808559	285.313892126083	158.220672607422	-328.289906859398	260.345497071743	157.92301893234
5	1100346565	278.419927537441	157.911098003387	-333.489711284637	283.432865083218	158.228731155396	-333.469442486763	258.189093947411	158.37211608886
6	1125617504	276.285858213902	157.780194282532	-338.25106793642	281.460406064987	158.033275604248	-338.221744894981	256.538791269064	158.4707617759
7	1324769974	276.138988852501	157.47971534729	-257.051277339458	281.334726810455	157.56106376648	-257.024194031954	256.530880719423	158.45367908477
8	1455491066	277.149092972279	156.769466400146	-292.152165174484	282.086864411831	156.884396076202	-292.110738039017	257.35146522522	157.82617330551
9	1043985367	277.822982847691	156.782305240631	-231.625690639019	282.74340826273	156.895303726196	-231.563041627407	258.129478901625	157.84065723419
10	1065309048	278.159197092056	155.22426366806	-248.7114135921	283.023200273514	155.508005619049	-248.638360142708	258.403679519892	156.53655529022
11	1545140505	278.347652435303	154.99552488327	-239.381110906601	283.178424954414	155.332732200623	-239.327579677105	258.267309904098	156.31942749023
12	1139793873	278.496586799622	154.864323139191	-302.848022520542	283.375362694263	155.178105831146	-302.81212323904	258.160978138447	156.27851486206
13	1742259502	278.589035391808	153.355610370636	-319.936493515968	283.522708594799	153.635561466217	-319.907837629318	258.320428133011	154.71397638320
14	1495601654	278.651811480522	153.443348407745	-334.139551818371	283.453133881092	153.667461872101	-334.116805016994	258.083762913942	154.73525524139
15	1459695816	278.275536179543	155.412685871124	-289.84428614378	283.090042829514	155.448138713837	-289.82017326355	257.470457047224	156.49021863937

Fonte - Autor

4.5 Considerações Finais do Capítulo

No presente capítulo foi detalhada a especificação da solução apresentada neste trabalho. O detalhamento passou pelo cenário onde a proposta foi desenvolvida, a análise de requisitos e as tecnologias para compor a solução. Referente as tecnologias escolhidas a Figura 20 ilustra a organização em camadas de tais tecnologias.

Figura 20 – Representação em camadas das tecnologias



Fonte - Autor

Como o cenário detalha que a solução desenvolvida possa fazer parte do cotidiano dos profissionais da área de reabilitação motora pós-AVC, os requisitos foram listadas funcionalidades que permitem que vários movimentos sejam configurados através de parametrização, que as sessões possam ser assistidas em um segundo momento e que a ferramenta auxilie no acompanhamento da evolução do paciente, além disso foram priorizadas tecnologias que não dependessem de alto poder computacional para que sejam executadas com qualidade, esta característica contribui para que a solução seja utilizada em clínicas com computadores populares.

5 DESENVOLVIMENTO

5.1 Considerações Iniciais do Capítulo

No presente capítulo é descrito a estrutura criada para o Banco de Dados e as funcionalidades da aplicação.


5.2 Banco de Dados

O Banco de Dados foi implementado por meio do SGBD SQLite descrito no item [4.4.6](#), na modelagem do Banco de Dados foram criadas as seguintes tabelas:

- Paciente: armazena os pacientes;
- Movimento: responsável por armazenar o registro básico dos movimentos;
- Param_movimento: armazena quais articulações serão utilizadas por movimento e indica que o ângulo será esperado ou de compensação, os dados desta tabela serão úteis para a parametrização dos ângulos por movimento;
- Angulo_movimento: tabela responsável por armazenar a parametrização de ângulos por movimentos através de três pontos para formar dois segmentos de retas para os ângulos gerados pelo movimento, os dados desta tabela serão úteis para gerar os dados de análise das sessões;
- Sessao_cab: armazena o dados gerais da sessão, como paciente, movimento, data e hora e identificação de integração com base de dados externa;
- Sessao_angulo: tabela responsável por armazenar os ângulos gerados durante a sessão, separando por ângulo esperado ou de compensação, os ângulos são registrados por frames, os dados armazenados nesta tabela serão úteis para o detalhamento da sessão e comparação entre sessões; e
- Sessao_item: armazena as posições das coordenadas X, Y e Z das sessões por frames, os dados desta tabela serão úteis para a reprodução da sessão e para a integração com a base de dados externa.

A representação da estrutura do banco de dados é ilustrada na Figura 22.

Figura 21 – Representação do diagrama de dados.



Fonte — Produzida pelo autor.

5.3 Funcionalidades


O desenvolvimento da aplicação foi realizado por funcionalidades, com isso, para maior clareza nesta dissertação as funcionalidades foram divididas entre:

- Entrada de dados: Funcionalidades que contemplam os cadastros e parametrizações possíveis na aplicação:
 - Cadastro de Pacientes;
 - Cadastro de Movimentos; e
 - Parametrização dos Ângulos dos Movimentos.
- Resultados: Funcionalidades que demonstram os resultados obtidos conforme cadastros e parametrizações realizadas:
 - Gravação da Sessão;
 - Reprodução da Sessão;

- Detalhes da Sessão; e
- Comparação entre Sessões.

Na Figura 22 é ilustrado o diagrama de interações do tipo de sequência da aplicação.

Figura 22 – Diagrama de interações do tipo sequência.



Fonte — Produzida pelo autor.

5.4 Funcionalidades de Entrada de Dados

Nesta seção as Funcionalidades de Entrada de Dados são detalhadas, tais funcionalidades apresentam importante papel na aplicação, onde a partir destas se torna possível o uso das Funcionalidades de Resultados.

5.4.1 Cadastro de Pacientes

Considerando que o que o profissional de saúde responsável pelo processo de reabilitação motora possa atender vários pacientes, a aplicação possibilita o cadastro de diferentes pacientes. Este cadastro é importante para toda a aplicação, pois permite que

os dados gerados pela aplicação com as sessões possam ser separados por pacientes. São disponibilizados os seguintes dados para cadastro do paciente:

- Nome: Nome do paciente, obrigatório;
- Peso: Peso do paciente, opcional; e
- Altura: Altura do paciente, opcional.

Os campos Peso e Altura foram considerados no cadastro do paciente visando a integração com a Base de Dados Externa, pois nesta integração existe a possibilidade para utilizar tais campos. O nome do paciente é fundamental para o profissional de saúde responsável pelo processo de reabilitação motora possa identificar o paciente nas demais funcionalidades da aplicação.

No cadastro de pacientes, é possível realizar a inclusão, alteração, exclusão e pesquisa de registros. A Figura 23 ilustra o cadastro de pacientes.

Figura 23 – Cadastro de Pacientes.

Identificação	Peso	Altura
Gabriel Rissatti Miguel	71	1,69

Fonte — Produzida pelo autor.

5.4.2 Cadastro de Movimentos

Diversas articulações do corpo humano podem ter movimentos afetados com o AVC, devido este fator, a aplicação com o intuito de não limitar o profissional de saúde responsável pelo processo de reabilitação motora em apenas determinadas articulações do corpo e em apenas determinados movimentos, possibilita que os movimentos que serão gravados durante as sessões sejam cadastrados, esta é uma importante funcionalidade que atua em prol à flexibilidade da ferramenta permitindo que diversos movimentos, tanto de membros superiores como de membros inferiores sejam considerados pela aplicação.

Para o cadastro de movimentos são tais articulações:

- Cabeça;

- Ombro esquerdo;
- Cotovelo esquerdo;
- Pulso esquerdo;
- Ombro direito;
- Cotovelo direito;
- Pulso direito;
- Quadril esquerdo;
- Joelho esquerdo;
- Tornozelo esquerdo;
- Pé esquerdo;
- Quadril direito;
- Joelho direito;
- Tornozelo direito; e
- Pé direito.

Para definir esta listagem foram considerados 2 fatores: Articulações utilizados pela Base de dados externas (esta aplicação integra) e articulações que o MediaPipe consegue rastrear, através da união destes conceitos chegou-se a esta listagem.

Ao cadastrar o movimento, deverá ser informado o nome do movimento e dois conjuntos de articulações, o primeiro conjunto de articulações será utilizado para formar o ângulo esperado do movimento, já o segundo conjunto será utilizado para formar um ângulo de compensação do movimento. Esta aplicação considera como ângulo esperado do movimento o principal ângulo que deverá ser gerado pela amplitude do membro afetado em determinado movimento. Já o ângulo de compensação é considerado o ângulo que não deveria ser formado pelas articulações em determinado movimento. Ambos poderão ser utilizados pelo o profissional de saúde responsável pelo processo de reabilitação motora para acompanhar a evolução do paciente durante as sessões.

A Figura 24 ilustra um exemplo da execução do movimento de "Elevação da Perna Esquerda", neste movimento o ângulo esperado é considerado como ângulo gerado pela elevação da perna esquerda (destacado em verde), já o ângulo de compensação é considerado como o ângulo gerado pela compensação da coluna vertebral (vermelho).


Conforme Figura 24, para a formação do ângulo esperado são consideradas as seguintes articulações:

- Quadril esquerdo;
- Tornozelo esquerdo; e
- Tornozelo direito.

Já para a formação do ângulo de compensação são considerados: Ombro direito e Ombro Esquerdo.

- Ombro esquerdo; e
- Ombro direito.

Figura 24 – Ilustração da formação de ângulos.



Fonte — Produzida pelo autor.

A aplicação não é específica para analisar a flexibilidade da perna e curvatura da coluna, no contexto da Figura 24 é ilustrado apenas um exemplo de uma situação que pode ocorrer, o conceito principal é que o sistema seja parametrizável para as necessidades dos pacientes.

No cadastro de movimentos, é possível realizar a inclusão, exclusão e pesquisa de registros, a cada movimento salvo em banco de dados, a aplicação utiliza 2 tabelas da estrutura: "Movimento" para nome e identificação e "Param_movimento" para as articulações que serão utilizadas para formação dos ângulos.

A Figura 25 ilustra o cadastro dos movimentos pela aplicação desenvolvida, nela é demonstrada as articulações selecionadas para o movimento conforme o ângulo a ser

considerado, assim como nomenclatura das colunas da grid "Esperado" e "Compensação". As articulações são salvas em linhas diferentes da tabela Param_movimento, para facilitar o entendimento do profissional de saúde responsável pelo processo de reabilitação motora foi realizado um tratamento via Python para exibir as articulações dos ângulos juntas na mesma coluna para não listando várias linhas.

Figura 25 – Cadastro de movimentos.

Identificação	Esperado	Compensação
Elevação lateral perna esquerda	13,15,19,	5,9,

Fonte — Produzida pelo autor.

5.4.3 Parametrização dos Ângulos dos Movimentos

Com os movimentos cadastrados e vinculados às articulações, se torna possível realizar a parametrização dos ângulos dos movimentos, no Cadastro de Movimentos foi necessário vincular as articulações para ângulos esperado e compensação, na Parametrização dos Ângulos tais vinculações são utilizadas nesta rotina.

Com o intuito de fornecer uma aplicação genérica que englobe vários movimentos e que atenda diversas demandas específicas conforme cada paciente, por exemplo analisar movimentos de membros superiores, inferiores ou tronco, o profissional de saúde responsável pelo processo de reabilitação motora poderá parametrizar dois segmentos de retas que deverão ter a mesma origem entre elas para formar um ângulo, este será o ângulo do movimento conforme tais critérios:

- Ponto O – Será o vértice (x_2, y_2), ponto inicial dos dois segmentos de retas
- Ponto 1 – Será o final do segmento de reta A (x_1, y_1)
- Ponto 2 – Será o final do segmento de reta B (x_3, y_3)

Com isso é obtido:

O = Vértice


Lados do ângulo:

$\overline{OA}, \overline{OB}$

$\widehat{AOB}$ = ângulo

A Figura 26 ilustra a formação de um ângulo pelos segmentos de retas em um avatar.

Figura 26 – Formação de um ângulo pelos segmentos de retas.



Fonte — Produzida pelo autor.

Para parametrizar os ângulos que serão formados, o profissional de saúde responsável pelo processo de reabilitação motora deverá escolher primeiramente o movimento, com isso, apenas as articulações vinculadas à este movimento no cadastro deste movimento que serão listadas, é possível notar isso na Figura 27, nela é ilustrado a parametrização dos ângulos do movimento "Elevação lateral perna esquerda", pode-se perceber que apenas

as articulações 13, 15 e 19 são listadas como opções para escolha, estas articulações são as mesmas vinculadas no cadastro do movimento ilustrado na Figura 25. Para cada um dos três Pontos utilizados para formar os dois segmentos de reta, deverá ser informado a posição X e Y.

Figura 27 – Parametrização de ângulos.

SalvarAjuda

Movimento {Elevação lateral perna esquerda} Carregar

Ângulo esperado

Ponto 1 - Final do segmento de reta A

X Y

13 15 19

Início dos segmentos de reta A e B

Y

Ponto 2 - Final do segmento de reta B

X Y

Ângulo de compensação

Ponto 1 - Final do segmento de reta A

X Y

Ponto O - Início dos segmentos de reta A e B

X Y

Ponto 2 - Final do segmento de reta B

X Y

Identificação	A_X	A_Y	B_X	B_Y	C_X	C_Y	Tipo de ângulo
Elevação lateral perna esquerda	19	19	13	13	15	15	Esperado
Elevação lateral perna esquerda	9	9	5	5	9	5	Compensação


Fonte — Produzida pelo autor.

Para auxiliar o profissional de saúde responsável pelo processo de reabilitação motora, nesta parametrização é disponibilizado um manual através do botão "Ajuda" e também é exibido um avatar com os pontos corporais em suas localizações. Esta funcionalidade de Parametrização dos Ângulos dos Movimentos é um dos diferenciais desta aplicação, pois ela permite que o profissional de saúde responsável pelo processo de reabilitação motora possa configurar os movimentos que considerar necessário para cada paciente, pois cada paciente possui sua particularidade e os membros comprometidos pelo AVC podem ser distintos, logo a possibilidade da escolha de distintas articulações possibilita que diversos movimentos possam ser analisados, toda essa flexibilidade da aplicação em que os movimentos são configurados não exigiu um pré-treinamento ou uma codificação específica para cada movimento. Esta funcionalidade da aplicação contribui também com estudos futuros, pois como esta aplicação possui a funcionalidade de alimentar um *Dataset*, este *Dataset* poderá receber diversos seções de reabilitação motora com uma variedade grande

de movimentos permitindo que estudos futuros possuam uma ampla fonte de dados.

A Figura 28 ilustra o manual disponibilizado na aplicação que pode ser acessado pelo botão "Ajuda".

Figura 28 – Manual para a parametrização de ângulos.



Fonte — Produzida pelo autor.

Com os ângulos parametrizados o profissional de saúde responsável pelo processo de reabilitação motora deverá clicar no botão "Salvar", este botão tem a finalidade de salvar a parametrização realizada, substituindo caso já exista alguma parametrização cadastrada para o mesmo movimento.

Com o cadastrado de pacientes, movimentos e parametrização de ângulos será possível a utilização das Funcionalidades de Resultados.

5.5 Funcionalidades de Resultados

Nesta seção as Funcionalidades de Resultados são detalhadas, tais funcionalidades podem ser utilizadas somente após cadastros e parametrizações realizadas nas Funcionalidades de Entrada de Dados. As Funcionalidades de Resultados possuem importante papel, pois a partir delas que pode-se obter os resultados da aplicação, ou seja, são estas Funcionalidades que geram valor agregado para o profissional de saúde responsável pelo processo de reabilitação motora.


5.5.1 Gravação da Sessão

Com os devidos cadastros e parametrizações realizadas no sistema, as sessões podem ser gravadas, para a gravação da sessão a distância entre o paciente e a câmera de captura de movimentos precisa ser em torno de 2 metros.

Inicialmente, o profissional de saúde responsável pelo processo de reabilitação motora precisa selecionar qual será o paciente da sessão, qual será o movimento realizado na sessão e qual o tipo de câmera está utilizada (se é uma câmera acoplada que é geralmente encontrada em notebooks ou uma câmera externa USB), esta escolha é necessária para que a aplicação consiga monitorar somente as articulações do movimento selecionado e formar os ângulos esperado e de compensação. Com paciente, movimento e tipo de câmera selecionados, a aplicação possibilita que seja projetada em tela a sessão pelo botão "Iniciar vídeo", esta é uma importante ação que contribui para que não seja gravado momentos pré-movimentos, como por exemplo a ajuste da posição do paciente, com a projeção em tempo real do paciente em tela, o MediaPipe é acionado para a detecção das articulações.

A Figura 29 ilustra a projeção do paciente na aplicação.

Figura 29 – Projeção do paciente na aplicação.




Fonte — Produzida pelo autor.

A aplicação conta com recursos visuais durante a projeção em tempo real do paciente, além das ligações gráficas entre as articulações desenhadas pelo MediaPipe, é possível que o profissional de saúde responsável pelo processo de reabilitação motora possa selecionar se quer exibir de forma gráfica os ângulos parametrizados.


A Figura 30 ilustra a representação gráfica do ângulo esperado em um polígono verde, já a Figura 31 ilustra a projeção do ângulo de compensação em um polígono vermelho e a Figura 32 ilustra a projeção de ambos ângulos.

Figura 30 – Representação gráfica em um polígono verde do ângulo esperado.




Fonte — Produzida pelo autor.

Figura 31 – Representação gráfica em um polígono vermelho do ângulo de compensação.



Fonte — Produzida pelo autor.

Figura 32 – Representação gráfica de ambos ângulos.



Fonte — Produzida pelo autor.

Os polígonos exibidos são criados pelas biblioteca OpenCV que combina as articulações do MediaPipe com a parametrização de ângulos da aplicação, a Figura 33 ilustra o código fonte desta funcionalidade para o ângulo de compensação.

Figura 33 – Representação gráfica de ambos ângulos.

```
a_x_n_space = pontos.pose_landmarks.landmark[mp_pose.PoseLandmark(a_x_n).value].x * frame_width
a_y_n_space = pontos.pose_landmarks.landmark[mp_pose.PoseLandmark(a_y_n).value].y * frame_height
b_x_n_space = pontos.pose_landmarks.landmark[mp_pose.PoseLandmark(b_x_n).value].x * frame_width
b_y_n_space = pontos.pose_landmarks.landmark[mp_pose.PoseLandmark(b_y_n).value].y * frame_height
c_x_n_space = pontos.pose_landmarks.landmark[mp_pose.PoseLandmark(c_x_n).value].x * frame_width
c_y_n_space = pontos.pose_landmarks.landmark[mp_pose.PoseLandmark(c_y_n).value].y * frame_height
vermelho = (0, 0, 255)
pts = numpy.array([(a_x_n_space, a_y_n_space), (b_x_n_space, b_y_n_space), (c_x_n_space, c_y_n_space)])
cv2.fillPoly(frame, numpy.int32([pts]), vermelho)
```

Fonte — Produzida pelo autor.

Outro recurso visual disponível é a indicação caso o paciente não esteja posicionado corretamente perante à câmera e o MediaPipe não consegue detectar as articulações para formar os ângulos, caso isso ocorra, é informado em tela uma mensagem distinta para cada um dos ângulos parametrizados para o movimento, a Figura 34 ilustra esta funcionalidade.

Figura 34 – Indicação de posicionamento incorreto.



Fonte — Produzida pelo autor.

Estes recursos visuais foram incorporados na aplicação para que auxilie o profissional de saúde responsável pelo processo de reabilitação motora a gravar somente o movimento das sessões evitando assim o armazenado de ruídos no sistema, como por exemplo o paciente se posicionando perante à câmera ou recebendo instruções de como realizar os exercícios físicos de reabilitação motora, a gravação de ruídos poderia prejudicar a análise futura a ser realizada com os dados armazenados além de ocupar espaço indevido no banco de dados.

Com o paciente posicionado corretamente, a sessão pode ter sua gravação iniciada, para isso o profissional de saúde responsável pelo processo de reabilitação motora precisa clicar no botão "Gravar", enquanto a gravação é realizada, é exibido na projeção a mensagem "Gravando", enquanto a sessão é gravada, as articulações do MediaPipe são armazenadas na tabela `sessao_item`, já os ângulos esperado e de compensação são armazenados na tabela `sessao_angulo`, ambas tabelas serão utilizadas para as funcionalidades de Reprodução da Sessão, Detalhes da Sessão e Comparação entre Sessões descritas nas próximas subseções desta dissertação.

5.5.2 Reprodução da Sessão

Logo que a gravação da sessão tiver sido finalizada, as funcionalidades de visualização da informação presentes na aplicação poderão ser exploradas. A primeira funcionalidade abordada é a Reprodução da Sessão. Esta funcionalidade possibilita que o profissional de saúde responsável pelo processo de reabilitação motora possa reproduzir cada uma das sessões que foram gravadas, a importância desta funcionalidade é que permite que cada sessão seja reproduzida quantas vezes for necessário para que ocorra a análise visual da mesma, com isso caso o profissional de saúde responsável pelo processo de reabilitação motora considerar importante, poderá exibir para o próprio paciente como foram seus movimentos indicando seus pontos de melhoria e sua evolução. Uma das vantagens desta funcionalidades é que a reprodução vídeos de várias sessões podem ser exibidas, tanto de sessões antigas como recentes.

A reprodução ocorre na própria aplicação, como a aplicação é projetada para ser executada em computadores convencionais de clínicas não foi considerado uma arquitetura robusta para Banco de Dados, esta aplicação utiliza o SQLite, para contribuir com esta solução que demanda uma estrutura menos robusta não são armazenados o vídeos da sessões, mas as posições das articulações a cada frame do vídeo, com isso o espaço utilizado para armazenamento é menor ao comparado se fosse armazenado o vídeo da sessão. A Figura 35 ilustra a recuperação de algumas colunas da tabela sessao_item, onde é armazenado os dados das posições das articulações das sessões.

Figura 35 – Recuperação de algumas colunas da tabela sessao_item.

idsessao	idframe	p0x	p0y	p0z	p1x	p1y	p1z	p2x	p2y	p2z
1	1	278.453666508198	167.648327350616	-379.303230643272	287.417208790779	157.661700248718	-359.701714634895	291.840953350067	157.981729507446	-359.692120313644
1	2	276.567365765572	167.739927768707	-420.916216373444	285.399828016758	157.668077945709	-401.157887220383	290.275141060352	157.99298286438	-401.150834441185
1	3	273.36114692688	167.763686180115	-364.454080581665	281.005438268185	157.481181621552	-344.904316723347	286.089094221592	157.822155952454	-344.951811790466
1	4	267.251343369484	167.767989635468	-350.005890548229	275.108139395714	157.590711116791	-328.29047870636	280.496017932892	157.884156703949	-328.308364808559
1	5	264.875176280737	167.988467216492	-356.355361521244	273.083610534668	157.666456699371	-333.479100346565	278.419927537441	157.911098003387	-333.489711284637
1	6	263.33356294441	167.983722686768	-359.771956503391	271.126686692238	157.622194290161	-338.243125617504	276.285858213902	157.780194282532	-338.25106793642
1	7	263.46673309803	167.660307884216	-282.093948960304	270.891816437244	157.449841499329	-257.029324769974	276.138988852501	157.47971534729	-257.051277339458
1	8	264.329713702202	167.07775592804	-318.955108821392	272.067629098892	156.742680072784	-292.158455491066	277.149092972279	156.769466400146	-292.152165174484
1	9	265.012292474508	167.196416854858	-260.879633903503	272.809314608574	156.751036643982	-231.653043985367	277.822982847691	156.782305240631	-231.625690639019
1	10	265.050844490528	165.103757381439	-277.798997044563	273.095365166664	155.096101760864	-248.756065309048	278.159197092056	155.22426366806	-248.7114135921
1	11	264.906897902489	164.850234985352	-271.30777156353	273.14625954628	154.833042621613	-239.410545140505	278.347652435303	154.99552488327	-239.381110906601
1	12	264.910614907742	164.861178398132	-333.886700153351	273.373568713665	154.74601984024	-302.878139793873	278.496586799622	154.864323139191	-302.848022520542
1	13	265.064330548048	164.295077323914	-346.387401819229	273.49534034729	153.311371803284	-319.972742259502	278.589035391808	153.355610370636	-319.936493515968
1	14	264.704988270998	164.957356452942	-356.922665476799	273.41486877203	153.448820114136	-334.149495601654	278.651811480522	153.443348407745	-334.139551818371
1	15	264.113619089127	167.824232578278	-309.44306999445	272.827391326427	155.613088607788	-289.799459695816	278.275536179543	155.412685871124	-289.84428614378
1	16	264.637383252382	168.513286113739	-312.66329908371	273.169514656067	156.04145526886	-289.992839276791	278.380660712719	155.899322032928	-290.049356818199


Fonte — Produzida pelo autor.

Com as posições das articulações armazenadas por frame, é possível reproduzir a sessão frame por frame, após recuperar os dados das posições das articulações armazenados no SQLite são aplicados recursos do MediaPipe para que através dessas posições das articulações seja desenhado um avatar que representa o corpo humano, então frame a frame é desenhado para que seja reproduzido em sequência para a sessão seja representada

fielmente.

Para que ocorra a reprodução da sessão, o profissional de saúde responsável pelo processo de reabilitação motora precisa inicialmente realizar uma pesquisa informando como parâmetros o movimento realizado e o paciente, com os parâmetros de pesquisa preenchidos, deve clicar no botão "Pesquisar", com isso, todas as sessões com tais parâmetros são listadas informando a data e hora da realização, assim como ilustrado na Figura 36.

Figura 36 – Pesquisa da sessão.




Sessão	Paciente	Movimento	Realização	Id Rebase
1	Gabriel Rissatti Miguel	MMSS direito	24/11/2023 21:56	65790c44bd143a93c9279013
118	Gabriel Rissatti Miguel	MMSS direito	30/11/2023 21:07	65790c47bd143a93c9279019
119	Gabriel Rissatti Miguel	MMSS direito	30/11/2023 21:08	65790c4abd143a93c927901f

Fonte — Produzida pelo autor.

Com os dados das sessões listados em tela, poderá agora selecionar qual sessão deseja assistir, para isso precisa clicar no botão "Assistir sessão", a reprodução da sessão é ilustrado na Figura 37.

Figura 37 – Visualização da sessão.



Fonte — Produzida pelo autor.

Por não armazenar o vídeo da sessão, a representação do corpo humano é realizada em formato de um avatar, além de otimizar o armazenamento esta opção contribui com a

preservação da privacidade do paciente, pois seu corpo não é apresentado em vídeo, apenas o movimento realizado agora por um avatar.

5.5.3 Detalhes da Sessão

Além da reprodução da sessão descrita na seção anterior, a aplicação possibilita que o profissional de saúde responsável pelo processo de reabilitação motora visualize os ângulos gerados pelo paciente em um gráfico de linhas. O objetivo deste gráfico é ilustrar a cada frame tanto o ângulo esperado quanto o de compensação para que as informações possam ser analisadas e correlacionadas se necessário, como por exemplo, em determinado movimento por determinado paciente pode-se notar o mesmo comportamento de ângulo de compensação sempre que o ângulo esperado possui determinado valor, pode-se também analisar a evolução do ângulo esperado do paciente.

Assim como a reprodução da sessão, a visualização deste gráfico ocorre na própria aplicação sem a necessidade da instalação de componentes adicionais no computador em que a aplicação é executada, e também da mesma forma que a reprodução da sessão, esta ferramenta de visualização recupera dados do SQLite para projetar o gráfico em tela. Os dados utilizados para esta ferramenta são recuperados da tabela `sessao_angulo`, esta tabela recebe registros sempre que ocorre a gravação de uma sessão, e a cada frame os ângulos esperado e de compensação são calculados e para que seja registrado nesta tabela.

A Figura 38 ilustra a função `CalcAngulo` que calcula os ângulos, a cada frame. A função `CalcAngulo` é executada duas vezes, uma para obter o ângulo esperado e uma segunda vez para obter o ângulo de compensação.

Figura 38 – Função `CalcAngulo`.

```
def CalcAngulo(pt1x, pt1y, pt2x, pt2y, pt3x, pt3y):  
    p1x = pt1x - pt2x  
    p1y = pt1y - pt2y  
    p3x = pt3x - pt2x  
    p3y = pt3y - pt2y  
    alfa = math.atan2(p1y, p1x)  
    beta = math.atan2(p3y, p3x)  
    return round(360 - math.fabs(numpy.degrees(alfa - beta)), 2)
```

Fonte — Produzida pelo autor.

A Figura 39 ilustra a recuperação de alguns registros de uma sessão da tabela `sessao_angulo`.


Figura 39 – Recuperação de alguns registros de uma sessão da tabela sessao_angulo..

	idsessao	idframe	esperado	compensacao
1	1	1	9.949999999999999	0.389999999999986
2	1	2	24.0	0.490000000000009
3	1	3	51.26	0.0400000000000205
4	1	4	95.43	2.62
5	1	5	108.13	3.63
6	1	6	127.09	7.33999999999998
7	1	7	145.19	12.2
8	1	8	159.69	14.52
9	1	9	164.62	17.01
10	1	10	149.34	15.57
11	1	11	134.67	14.58
12	1	12	120.62	13.84
13	1	13	99.68	11.47
14	1	14	79.14	6.12

Fonte — Produzida pelo autor.

A aplicação possibilita que este gráfico seja gerado pelo profissional de saúde responsável pelo processo de reabilitação motora assim que a gravação da sessão é encerrada e com pouco processamento computacional. Para visualizar o gráfico contendo os detalhes da sessão, é necessário realizar a mesma pesquisa de paciente e movimento descrita na seção anterior (Reprodução da Sessão), porém agora é necessário clicar no botão "Detalhar Sessão", com isso, é exibido na aplicação o gráfico detalhando a sessão escolhida. Na Figura 40 é ilustrado o gráfico gerado.

Figura 40 – Detalhes da sessão.



Fonte — Produzida pelo autor.

Nota-se na Figura 40 que cada um dos ângulos são representados por diferentes linhas, a linha na cor azul representa o ângulo esperado e a linha na cor laranja representa o ângulo de compensação, nota-se ainda na Figura 40, que o gráfico indica que possivelmente o movimento foi realizado 3 vezes através dos valores do ângulo esperado, e que durante a segunda repetição ocorreu a formação do maior ângulo de compensação do paciente.


5.5.4 Comparação entre Sessões

A funcionalidade de Comparação entre Sessões possibilita que o profissional de saúde responsável pelo processo de reabilitação motora possa analisar todas as sessões de um mesmo paciente e um mesmo movimento realizados no formato de gráfico de linhas, diferentemente da funcionalidade "Detalhes da Sessão" que ilustra todos de ângulos gerados a cada frame de uma única sessão, a funcionalidade de "Comparação entre Sessões" ilustra somente os maiores ângulos gerados por sessão, ordenando de forma crescente pela data da sessão. Esta função tem a finalidade de ilustrar de forma direta um resumo de cada sessão para que possa ser realizada uma análise e comparação da evolução do paciente no decorrer do tempo, em que pode ser verificado os seguintes fatores:

- Quantia de sessões;
- Tempo de tratamento;
- Resultado conforme tempo e quantia de sessões;
- Maior ângulo esperado gerado em cada sessão; e
- Maior ângulo de compensação gerado em cada sessão.

Assim como na funcionalidade "Detalhes da Sessão", no gráfico gerado pela função "Comparação entre Sessões" cada um dos ângulos são representados por diferentes linhas, a linha na cor azul representa o ângulo esperado e a linha na cor laranja representa o ângulo de compensação, A Figura 41 ilustra o gráfico gerado:

Figura 41 – Análise entre sessões.



Fonte — Produzida pelo autor.

Na Figura 41, é ilustrada a comparação entre 3 sessões, a primeira sessão com data de 28/11/2023 e as seguintes com data de 30/11/2023.

5.5.5 Integração com Ferramenta Externa


Existe uma grande demanda no desenvolvimento de aplicações para uso em tratamentos de reabilitação neuromotora. Muitas destas aplicações são de realidade virtual e realidade aumentada, isso permite que os usuários interajam com esses aplicativos possibilitando a recuperação e análise dos dados gerados pelos seus movimentos durante o tratamento. Todavia não é fácil encontrar conjuntos de dados de movimentos corporais e os disponíveis não incluem movimentos específicos no contexto da reabilitação, para sanar este problema foi criado o Rehabilitation Database (Rebase) por um grupo de pesquisa (BARBOSA et al., 2021). Esta afirmação reforça a necessidade de alimentação de um *dataset* de movimentos de reabilitação motora.

A forma de integração entre a aplicação e o Rebase é através de API (Application Programming Interface), tais APIs são fornecidas pela estrutura do Rebase que as aplicações consumam tais APIs.

Para que ocorra a integração com a ferramenta Rebase, o profissional de saúde responsável pelo processo de reabilitação motora precisa inicialmente acessar o menu

"Integração com Rebase" e realizar uma pesquisa informando como parâmetros o movimento realizado e o paciente, com os parâmetros de pesquisa preenchidos, deve clicar no botão "Pesquisar", com isso, todas as sessões com tais parâmetros e que ainda não foram integradas com o Rebase são listadas assim como ilustrado na Figura 42.

Figura 42 – Sessões ainda não integradas com Rebase.



The screenshot shows a web application interface. At the top, there are two search filters: 'Movimento' with a dropdown menu showing '(MMSS esquerdo)' and 'Paciente' with a dropdown menu showing '(Gabriel Rissatti Miguel)'. Below these filters are two buttons: 'Pesquisar' (Search) and 'Integrar' (Integrate). Below the buttons is a table with the following data:

Sessão	Paciente	Movimento	Realização
123	Gabriel Rissatti Miguel	MMSS esquerdo	25/01/2024 21:32
124	Gabriel Rissatti Miguel	MMSS esquerdo	25/01/2024 21:39

Fonte — Produzida pelo autor.

Para realizar a integração é necessário selecionar qual a sessão a ser integrada e clicar no botão "Integrar", com isso a aplicação executará de forma sequenciada e dependente duas APIS, primeiramente executará a API "session" para o registro da sessão caso o retorno for positivo executará a API "movement" para o registro dos movimentos da sessão cadastrada.

A Figura 43 ilustra um exemplo de dados enviados para a API "session".

Figura 43 – Dados enviados para o cadastro da sessão.

```
{
  "session": {
    "title": "Teste título",
    "description": "Descrição aqui",
    "patient": {
      "id": "VoluntárioGabriel",
      "age": 35,
      "weight": 70,
      "height": 1.69
    },
    "professionalId": "GabrielRissattiMiguel_Testex"
  }
}
```

Fonte — Produzida pelo autor.

Já Figura 44 ilustra um exemplo de dados enviados para a API "movement".

Figura 44 – Dados enviados para o vinculação de movimentos na sessão.

```


{
  "movement": {
    "device": "MediaPipe",
    "duration": 60,
    "registers": [
      {
        "1": [
          -356,
          -1.83,
          172.32
        ],
        "2": [
          -351.58,
          -357.83,
          169.47
        ]
      },
      {
        "1": [
          359.11,
          358.77,
          288.11
        ],
        "2": [
          356.32,
          354.29,
          294.44
        ]
      }
    ]
  },
  "label": "LabeldoMovimento",
  "sessionId": "6577b3c29b8b7b022b1098f4"
}

```

Fonte — Produzida pelo autor.

Após a integração com a ferramenta Rebase, é possível consultar o código gerado pelo Rebase para a sessão que foi integrada, é possível visualizar o código gerado pelo Rebase na coluna "Id Rebase", a Figura 45 ilustra esta funcionalidade.

Figura 45 – Visualização do código gerado pelo Rebase.



Sessão	Paciente	Movimento	Realização	Id Rebase
1	Gabriel Rissatti Miguel	MMSS direito	24/11/2023 21:56	65790c44bd143a93c9279013
118	Gabriel Rissatti Miguel	MMSS direito	30/11/2023 21:07	65790c47bd143a93c9279019
119	Gabriel Rissatti Miguel	MMSS direito	30/11/2023 21:08	65790c4abd143a93c927901f
122	Gabriel Rissatti Miguel	MMSS direito	05/12/2023 15:24	6578ff0c9b8b7b022b1099e7

Fonte — Produzida pelo autor.

5.6 Considerações Finais do Capítulo

Neste capítulo foi apresentado o processo de construção da ferramenta, a estrutura de banco de dados, módulos e funcionalidades. Com disso, foi demonstrado o funcionamento e objetivo da aplicação passando pelos cadastros, obtenção de dados e resultados, desta forma pode-se compreender melhor sua importância dentro do projeto.

Durante o processo de construção da ferramenta as sessões foram gravados com o autor do projeto no papel do paciente para que tornasse possível ilustrar as funcionalidades da aplicação de uma forma prática.

6 CONCLUSÃO

6.1 Considerações Iniciais do Capítulo

O presente capítulo tem como objetivo descrever a conclusão do projeto, apresentando o atendimento aos objetivos, trabalhos futuros e considerações finais.

6.2 Atendimento aos Objetivos

Os 6 objetivos específicos descritos desta dissertação descritos no Capítulo 1, foram atendidos.

Referente o objetivo 1, "Realizar uma revisão sistemática de conteúdo acerca da utilização da Visualização da Informação e Inteligência Artificial aplicada à Análise de Movimentos", foi atendido no Capítulo 3 onde apresentada uma RSL que respondeu as perguntas elaboradas, os resultados obtidos colaboraram para que a especificação da arquitetura fosse elaborada.

O objetivo 2, "Propor a arquitetura de uma solução parametrizável para diversos movimentos e que permita a gravação de sessões a e consulta de resultados"foi atendido no Capítulo 4, neste Capítulo foi apresentada a especificação da solução, com os requisitos, tecnologias utilizadas, diagrama de caso de uso e arquitetura em camadas, a arquitetura da aplicação foi um importante insumo para o desenvolvimento.

Já o objetivo 3, "Aplicar o design proposto e desenvolver uma aplicação para registro de sessões de reabilitação motora pós-AVC e consultas de resultados"foi atendido no Capítulo 5, neste Capítulo foi apresentado o desenvolvimento da solução de forma geral, nos próximos objetivos são detalhadas as funcionalidades esperadas na aplicação.

O objetivo 4 "Criar um mecanismo de entrada de dados parametrizável que consiga abranger situações distintas de pacientes para a alimentação de um *dataset* de movimentos para estudos futuros"foi atendido na seção 5.4, nesta subseção foram apresentados os cadastros e a parametrização dos ângulos dos movimentos, estas funcionalidades foram denominadas "Funcionalidades de Entrada de Dados". Tais funcionalidades representam importante papel na aplicação pois permite que o profissional de saúde responsável pelo processo de reabilitação motora cadastre e parametrize diversas situações para trabalhar e coletar os resultados, estes resultados podem ainda alimentar um *dataset* de movimentos para estudos futuros.

A partir dos cadastros e parametrizações pois foi possível realizar a gravação das

sessões personalizadas para diversos pacientes e movimentos, esta possibilidade é descrita na subseção 5.5.1, logo o objetivo 5 "A partir dos dados parametrizados, ser possível registrar sessões de reabilitação motora de pacientes onde nestas sessões características dos movimentos sejam registradas", foi atendido. Além da personalização das sessões, esta gravação parametrizável possui recursos gráficos para auxiliar o profissional de saúde responsável pelo processo de reabilitação motora. Esta funcionalidade faz parte do grupo "Funcionalidades de Resultados"descrito na seção 5.5.

Já o objetivo 6 "Desenvolver rotinas para a visualização de resultados das sessões de forma gráfica e permitir que as sessões gravadas possam ser reproduzidas"foi atendido pelas Funcionalidades de Resultados "Reprodução da Sessão"descrita na subseção 5.5.2, "Detalhes da Sessão"apresentada na subseção 5.5.3 e na funcionalidade "Comparação entre Sessões"apresentada na subseção 5.5.4, tais recursos agregam grande valor na aplicação, pois permitem que as sessões sejam reproduzidas sempre que necessário com uso de um avatar, através de gráficos o profissional de saúde responsável pelo processo de reabilitação motora pós-AVC pode analisar uma sessão específica ou comparar várias sessões de um paciente.

O objetivo 7 "Integrar os dados gerados na sessões com uma ferramenta externa para contribuição científica e estudos futuros"foi atendido pela funcionalidade "Integração com Ferramenta Externa"descrita na subseção 5.5.5, esta é uma importante funcionalidade para colaboração com trabalhos futuros.

Por fim, o objetivo geral, objetivos específicos e a contribuição almejada pela aplicação foram atendidos em sua totalidade.

6.3 Trabalhos Futuros e Continuidade

Inicialmente esta dissertação contemplou uma aplicação com interface gráfica que ainda não pode ser executada em ambiente mobile e web, logo tornar a aplicação híbrida é um ponto a ser considerado na continuidade da aplicação.

Atualmente, a aplicação encontra-se somente com o grupo de pesquisa BRAINN e associados, a qual iniciou o uso e coleta de dados, futuramente visando uma expansão na abrangência de usuários e em conjunto com a disponibilização de uma versão híbrida, um fator importante a ser considerado é a gestão de acessos com credenciais para autenticação, esta gestão de acessos será incorporada ao cadastro de um profissional de saúde responsável pelo processo de reabilitação motora que atualmente não existe na aplicação.

Com a coleta de dados iniciada, parte da continuação deste trabalho visa a criação de modelo de classificação em IA e a aplicação do XAI, tais itens foram considerados na pesquisa da RSL porém foram removidos devido a sinergia de tempo para a coleta de dados

em larga escala para a criação de um modelo de IA e aplicação de XAI para explicação das decisões classificatórias, porém toda a estrutura para a criação e alimentação da base foi contemplada na aplicação.

Outro fator a ser considerado em versões futuras do trabalho é a inclusão do posicionamento Z das articulações, pois o trabalho atual considera somente as posições X e Y, somente foram consideradas tais posições para validar o processo de parametrização disponibilizado.

Por fim, como melhoria futura, agregando funcionalidades a serem implementadas descritas nesta sessão, unindo a gestão de acessos com a coleta da dados, tem-se o objetivo da criação de uma área analítica para visualização de gráficos considerando novas oportunidades através da recuperação de dados do Rebase para que pesquisadores possam ter acesso à uma fonte mais rica de dados para utilizarem em prol à recuperação dos pacientes.

6.4 Considerações Finais

Neste trabalho objetivou auxiliar os profissionais de saúde responsáveis pelo processo de reabilitação motora pós-AVC com o uso de Visão computacional e IA. Foi disponibilizada uma aplicação que atualmente está sendo utilizada pelo grupo de pesquisa BRAINN e associados, tal aplicação possui flexibilidade pois permite que movimentos e ângulos sejam parametrizados na aplicação. Além da coleta da dados de dados a aplicação permite que dados das sessões sejam analisados e também que sessões sejam reproduzidas assegurando a privacidade dos pacientes, objetivando estudos futuros de outros pesquisadores, a aplicação integra à um Banco de dados externo.

A RSL demonstrou grande contribuição em relação à diretrizes tomadas no desenvolvimento da aplicação, onde 26 artigos foram selecionados para este projeto.

Por fim, foram levantadas melhorias futuras que serão aplicadas na continuidade deste trabalho.

Referências

- ABDELBAKY, A.; ALY, S. Human action recognition based on simple deep convolution network pcanet. In: *2020 International Conference on Innovative Trends in Communication and Computer Engineering (ITCE)*. [S.l.: s.n.], 2020. p. 257–262. Citado 5 vezes nas páginas 34, 37, 39, 42 e 47.
- ACM. *About the ACM Digital Library*. 2022. <https://dlnext.acm.org/about>. Acesso 27-06-2022. Citado na página 26.
- AL-FARIS, M. et al. A review on computer vision-based methods for human action recognition. *Journal of imaging*, MDPI AG, Basel, v. 6, n. 6, p. 46, 2020. ISSN 2313-433X. Citado 6 vezes nas páginas 23, 34, 37, 39, 42 e 47.
- AL-WESABI, F. N. et al. Design of optimal deep learning based human activity recognition on sensor enabled internet of things environment. *IEEE Access*, v. 9, p. 143988–143996, 2021. Citado 7 vezes nas páginas 33, 37, 38, 40, 42, 45 e 47.
- BACKES, J. J. S. J. A. R. *Introdução à Visão Computacional Usando MATLAB*. 1ª.. ed. [S.l.]: Alta Books, 2016. Citado 2 vezes nas páginas 21 e 22.
- BARBOSA, T. et al. Rebase: data acquisition and management system for neuromotor rehabilitation supported by virtual and augmented reality. In: *Anais do XXIII Simpósio de Realidade Virtual e Aumentada*. Porto Alegre, RS, Brasil: SBC, 2021. p. 181–185. Disponível em: <<https://sol.sbc.org.br/index.php/svr/article/view/17535>>. Citado na página 82.
- BAUR, T. et al. I see what you did there: Understanding when to trust a ml model with nova. In: *2019 8th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*. [S.l.: s.n.], 2019. p. 77–78. Citado 2 vezes nas páginas 34 e 47.
- BOLAND ANGELA, e. a. D. a. Systematic review:: A student's guide. *SAGE Publications*, p. 240, 2013. Citado 2 vezes nas páginas 25 e 26.
- BOUALIA, S. N.; AMARA, N. E. B. Pose-based human activity recognition: a review. In: *2019 15th International Wireless Communications Mobile Computing Conference (IWCMC)*. [S.l.: s.n.], 2019. p. 1468–1475. Citado 6 vezes nas páginas 23, 34, 36, 38, 47 e 48.
- BRANDAO, A. *Aplicações de realidade virtual despontam como novas possibilidades às sessões de fisioterapia e terapia ocupacional*. 2016. <https://www.brainn.org.br/aplicacoes-de-realidade-virtual-despontam-como-novas-possibilidades-as-sessoes-de-fisioterapia-e-terapia-ocupacional/>. Acessado em 18/05/2023. Citado 2 vezes nas páginas 16 e 17.
- CAPES. *Quem somos*. 2022. <https://www-periodicos-capes-gov-br.ezl.periodicos.capes.gov.br/index.php/sobre/quem-somos.html>. Acesso 28-06-2022. Citado na página 26.

CHAPMAN, S. J. *Programação em MATLAB para engenheiros*. [S.l.]: Pioneira Thomson Learning, 2003. Citado na página 43.

DU, C. et al. Assessing physical rehabilitation exercises using graph convolutional network with self-supervised regularization. In: *2021 43rd Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*. [S.l.: s.n.], 2021. p. 281–285. Citado 9 vezes nas páginas 15, 16, 33, 37, 39, 42, 43, 45 e 47.

F, A. M.; SINGH, S. Computer vision-based survey on human activity recognition system, challenges and applications. In: *2021 3rd International Conference on Signal Processing and Communication (ICPSC)*. [S.l.: s.n.], 2021. p. 110–114. Citado 4 vezes nas páginas 23, 24, 33 e 47.

FIORINI, L. et al. Daily gesture recognition during human-robot interaction combining vision and wearable systems. *IEEE sensors journal*, IEEE, New York, v. 21, n. 20, p. 23568–23577, 2021. ISSN 1530-437X. Citado 7 vezes nas páginas 33, 37, 38, 39, 43, 45 e 47.

FOUNDATION, P. S. *Python Software Foundation*. 2022. Acessado em 08/07/2022. Disponível em: <<https://www.python.org/psf/>>. Citado na página 55.

GAMMULLE, H. et al. Two stream lstm: A deep fusion framework for human action recognition. In: *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*. [S.l.: s.n.], 2017. p. 177–186. Citado 5 vezes nas páginas 34, 38, 39, 42 e 47.

GOOGLE. *Pose landmark detection guide*. 2022. Acessado em 01/10/2022. Disponível em: <https://developers.google.com/mediapipe/solutions/vision/pose_landmarker>. Citado na página 58.

IEEE. *About IEEE Xplore*. 2022. <https://ieeexplore.ieee.org/Xplorehelp/overview-of-ieee-xplore/about-ieee-xplore>. Acesso 28-06-2022. Citado na página 27.

IMAMBI, S.; PRAKASH, K. B.; KANAGACHIDAMBARESAN, G. R. Pytorch. In: _____. *Programming with TensorFlow: Solution for Edge Computing Applications*. Cham: Springer International Publishing, 2021. p. 87–104. ISBN 978-3-030-57077-4. Disponível em: <https://doi.org/10.1007/978-3-030-57077-4_10>. Citado na página 44.

JETBRAINS. *About JetBrains*. 2023. Acessado em 25/05/2023. Disponível em: <<https://www.jetbrains.com/pt-br/company/>>. Citado na página 55.

JETBRAINS, P. S. F. e. *Resultados da Pesquisa de 2021 para desenvolvedores Python*. 2022. Acessado em 25/05/2023. Disponível em: <https://lp.jetbrains.com/pt-br/python-developers-survey-2021/?_gl=1*i4s612*_ga*MTY2MDAzNzI4OC4xNjg1MDY1NDgz*_ga_9J976DJZ68*MTY4NTA2NTQ4Mi4xLjEuMTY4NTA2NjExNi4yMi4wLjA.&_ga=2.191082924.741185258.1685065483-1660037288.1685065483>. Citado na página 55.

JIA, Y. et al. Caffe: Convolutional architecture for fast feature embedding. *arXiv preprint arXiv:1408.5093*, 2014. Citado na página 57.

JOGIN, M. et al. Feature extraction using convolution neural networks (cnn) and deep learning. In: *2018 3rd IEEE International Conference on Recent Trends in Electronics, Information Communication Technology (RTEICT)*. [S.l.: s.n.], 2018. p. 2319–2323. Citado 5 vezes nas páginas 34, 37, 40, 42 e 47.

- KAUFMAN, D. *A inteligência artificial irá suplantará a inteligência humana?* 3ª.. ed. [S.l.]: ESTACAO DAS LETRAS E CORES EDITORA LTDA, 2019. Citado na página 20.
- KIM, S.-T.; LEE, H. J. Lightweight stacked hourglass network for human pose estimation. MDPI AG, Basel, v. 10, n. 18, p. 6497, 2020. ISSN 2076-3417. Citado 6 vezes nas páginas 23, 34, 38, 40, 45 e 47.
- KIM, S.-T.; LEE, H. J. Lightweight stacked hourglass network for human pose estimation. *Applied sciences*, MDPI AG, Basel, v. 10, n. 18, p. 6497, 2020. ISSN 2076-3417. Citado 5 vezes nas páginas 34, 38, 39, 43 e 47.
- KUEHNE, H. et al. HMDB: a large video database for human motion recognition. In: *Proceedings of the International Conference on Computer Vision (ICCV)*. [S.l.: s.n.], 2011. Citado na página 41.
- LAPTEV, B. C. I. *Recognition of human actions*. 2005. Acessado em 08/07/2022. Disponível em: <<https://www.csc.kth.se/cvap/actions/>>. Citado na página 41.
- LUGARESI, C. et al. *MediaPipe: A Framework for Building Perception Pipelines*. 2019. Citado na página 58.
- MENEZES, N. N. C. *Introdução a programação com python*. São Paulo: Novatec, 2010. Citado na página 55.
- MORO, M. et al. Markerless gait analysis in stroke survivors based on computer vision and deep learning: A pilot study. In: _____. Association for Computing Machinery, 2020. p. 2097–2104. ISBN 9781450368667. Disponível em: <<https://doi.org/10.1145/3341105.3373963>>. Citado 6 vezes nas páginas 34, 38, 39, 42, 45 e 47.
- MURRAY, D.; STANKOVIC, L.; STANKOVIC, V. Explainable nilm networks. In: _____. New York, NY, USA: Association for Computing Machinery, 2020. p. 64–69. ISBN 9781450381918. Citado 3 vezes nas páginas 21, 34 e 47.
- NOORI, F. M.; WALLACE BENEDIKTEAND UDDIN, M. Z. T. J. A robust human activity recognition approach using openpose, motion features, and deep recurrent neural network. In: FELSBURG, M. et al. (Ed.). *Image Analysis*. Cham: Springer International Publishing, 2019. p. 299–310. ISBN 978-3-030-20205-7. Citado na página 43.
- OPENCV. *About*. 2023. Acessado em 01/06/2023. Disponível em: <<https://opencv.org/about/>>. Citado na página 56.
- PANG, B.; NIJKAMP, E.; WU, Y. N. Deep learning with tensorflow: A review. *Journal of Educational and Behavioral Statistics*, v. 45, n. 2, p. 227–248, 2020. Disponível em: <<https://doi.org/10.3102/1076998619872761>>. Citado na página 44.
- PARK, J. et al. A body part embedding model with datasets for measuring 2d human motion similarity. *IEEE Access*, v. 9, p. 36547–36558, 2021. Citado 8 vezes nas páginas 16, 33, 36, 37, 39, 42, 47 e 48.
- PYTHON.ORG. *Interface Python para Tcl/Tk*. 2024. Acessado em 03/02/2024. Disponível em: <<https://docs.python.org/pt-br/3/library/tkinter.html>>. Citado na página 59.

- RUPPRECHTER, S. et al. A clinically interpretable computer-vision based method for quantifying gait in parkinson's disease. *Sensors (Basel, Switzerland)*, MDPI AG, Basel, v. 21, n. 16, p. 5437, 2021. ISSN 1424-8220. Citado 8 vezes nas páginas 33, 37, 38, 40, 42, 43, 44 e 47.
- SAMPAIO, R. Estudos de revisão sistemática: Um guia para síntese criteriosa da evidência científica. *Revista Brasileira De Fisioterapia - REV BRAS FISIOTER*, v. 11, 02 2007. Citado na página 25.
- SAÚDE, M. da Saúde Biblioteca Virtual em. *Acidente vascular cerebral (AVC)*. 2015. Acessado em 16/06/2022. Disponível em: <<https://bvsms.saude.gov.br/avc-acidente-vascular-cerebral/>>. Citado na página 15.
- SCHIMIT CLARISSA SELAU, P. S. E. F. V. P. e. L. Q. M. Acidente vascular cerebral e diferentes limitações: Uma análise interdisciplinar. *Arq. Ciênc. Saúde UNIPAR*, v. 23, n. 2, Agosto 2019. Disponível em: <<https://pesquisa.bvsalud.org/portal/resource/pt/biblio-996725>>. Citado na página 15.
- SCHLEGEL, U. et al. Towards a rigorous evaluation of xai methods on time series. In: *2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*. [S.l.: s.n.], 2019. p. 4197–4201. Citado 5 vezes nas páginas 34, 38, 39, 42 e 47.
- SHETH, A. et al. Knowledge-intensive language understanding for explainable ai. *IEEE Internet Computing*, v. 25, n. 5, p. 19–24, 2021. Citado 3 vezes nas páginas 21, 33 e 47.
- SILVA, C. H. P. M. ŠJennifer Amanda Sobral da. Inteligência artificial: aliada ou inimiga. *Rev. Ciênc. Soc. Apl, IEEE*, v. 9, n. 2, p. 64–85, 2019. Citado na página 20.
- SIQUEIRA PALOMA SCHNEIDERS, A. S. S. Intervenções fisioterapêuticas e sua efetividade na reabilitação do paciente acometido por acidente vascular cerebral. *Fisioterapia Brasil*, v. 20, n. 4, Agosto 2019. Disponível em: <https://docs.bvsalud.org/biblioref/2021/07/1281611/intervencoes-fisioterapeuticas-e-sua-efetividade-na-reabilitac_2JR0ofK.pdf>. Citado 2 vezes nas páginas 15 e 54.
- SLIJEPCEVIC, D. et al. Explaining machine learning models for clinical gait analysis. *Association for Computing Machinery*, v. 3, n. 2, 2021. ISSN 2691-1957. Disponível em: <<https://doi.org/10.1145/3474121>>. Citado 6 vezes nas páginas 33, 37, 40, 42, 45 e 47.
- SOOMRO, A. R. Z. K.; SHAH, M. Ucf101: A dataset of 101 human actions classes from videos in the wild. *Center for Research in Computer Vision University of Central Florida*, 2012. Citado na página 41.
- SQLITE. *About SQLite*. 2023. Acessado em 08/02/2024. Disponível em: <<https://www.sqlite.org/about.html>>. Citado na página 59.
- SZELISKI, R. *Computer Vision: Algorithms and Applications*. 2^a. ed. [S.l.]: Springer, 2021. Citado na página 22.
- TANG, D. Hybridized hierarchical deep convolutional neural network for sports rehabilitation exercises. *IEEE Access*, v. 8, p. 118969–118977, 2020. Citado 3 vezes nas páginas 34, 40 e 47.

- TANG, Y. et al. Layer-wise training convolutional neural networks with smaller filters for human activity recognition using wearable sensors. *IEEE sensors journal*, IEEE, Ithaca, v. 21, n. 1, p. 581–592, 2021. ISSN 1530-437X. Citado 6 vezes nas páginas 33, 38, 40, 42, 45 e 47.
- TEIXEIRA, J. de F. *O que é inteligência artificial*. 3ª.. ed. [S.l.]: e-galáxia, 2019. Citado na página 20.
- ULLAH, H. A. et al. Analysis of deep neural networks for human activity recognition in videos—a systematic literature review. *IEEE Access*, v. 9, p. 126366–126387, 2021. Citado 6 vezes nas páginas 33, 37, 39, 43, 45 e 47.
- VAKANSKI D. PAUL, R. B. H.-p. J. A. *University of Idaho - Physical Rehabilitation Movements Data Set (UI-PRMD)*. 2018. Acessado em 08/07/2022. Disponível em: <<https://www.webpages.uidaho.edu/ui-prmd/>>. Citado na página 40.
- XIE, B.; LI, B.; HARLAND, A. Movement and gesture recognition using deep learning and wearable-sensor technology. In: . Association for Computing Machinery, 2018. (AIPR 2018), p. 26–31. ISBN 9781450365246. Disponível em: <<https://doi.org/10.1145/3268866.3268890>>. Citado 7 vezes nas páginas 34, 38, 40, 42, 44, 45 e 47.
- YILMAZ, A. A. et al. A novel action recognition framework based on deep-learning and genetic algorithms. *IEEE access*, IEEE, Piscataway, v. 8, p. 100631–100644, 2020. ISSN 2169-3536. Citado 6 vezes nas páginas 33, 37, 39, 42, 45 e 47.
- ZHANG, C. et al. An augmented treble stream deep neural network for video analysis. In: *2020 24th International Conference Information Visualisation (IV)*. [S.l.: s.n.], 2020. p. 301–306. Citado 6 vezes nas páginas 33, 37, 39, 43, 45 e 47.
- ŠIMIĆ, I.; SABOL, V.; VEAS, E. Xai methods for neural time series classification: A brief review. 2021. Citado 2 vezes nas páginas 33 e 47.