

**INSTITUTO  
FEDERAL**

Alagoas

**INSTITUTO FEDERAL DE ALAGOAS**

**CAMPUS MACEIÓ**

**BACHARELADO EM SISTEMAS DE INFORMAÇÃO**

**HEBERT DOUGLAS DA SILVA CAMPOS**

**ANÁLISE DE MOVIMENTOS MOTORES FINOS DOS DEDOS  
UTILIZANDO VISÃO COMPUTACIONAL:  
UM ESTUDO DE CASO DO *FINGER TAPPING TEST (FTT)* NA DOENÇA  
DE PARKINSON**

MACEIÓ - AL

2023

HEBERT DOUGLAS DA SILVA CAMPOS

ANÁLISE DE MOVIMENTOS MOTORES FINOS DOS DEDOS  
UTILIZANDO VISÃO COMPUTACIONAL:  
UM ESTUDO DE CASO DO *FINGER TAPPING TEST (FTT)* NA DOENÇA  
DE PARKINSON

Trabalho de conclusão de curso apresentado ao do curso de Bacharelado em Sistemas de Informação do Instituto Federal de Alagoas - *Campus* Maceió como requisito para a obtenção do título de Bacharel em Sistemas de informação.

Orientador: Prof. Dr. Leonardo Melo de Medeiros

Coorientador: Prof. Dr. Arlyson Alves do Nascimento

MACEIÓ - AL  
2023



**Dados Internacionais de Catalogação na Publicação**  
**Instituto Federal de Alagoas**  
**Campus Maceió**  
**Biblioteca Benevides Monte**

---

006.3

C198a Campos, Hebert Douglas da Silva.

Análise de movimentos motores finos dos dedos utilizando visão computacional [recurso eletrônico] : um estudo de caso do *Finger Tapping Test* (FTT) na doença de Parkinson / Hebert Douglas da Silva Campos. – Dados eletrônicos (1 arquivo : 1,29 MB). – 2023.

Sistema requerido: Adobe Acrobat Reader.

Modo de acesso: Internet.

Orientação: Prof. Dr. Leonardo Melo de Medeiros.

Coorientação: Prof. Dr. Arlyson Alves do Nascimento.

Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) – Instituto Federal de Alagoas, *Campus Maceió*, Maceió, 2025.

1. Sistemas de Informação. 2. Visão computacional – Sistema. 3. Doença de Parkinson. 4. Teste de Toque de Dedos. 5. *Finger Tapping Test* (FTT). I. Título.

---

**Franciane Monick Gomes de França**  
**Bibliotecária – CRB 4/1831**

HEBERT DOUGLAS DA SILVA CAMPOS

ANÁLISE DE MOVIMENTOS MOTORES FINOS DOS DEDOS  
UTILIZANDO VISÃO COMPUTACIONAL:  
UM ESTUDO DE CASO DO *FINGER TAPPING TEST (FTT)* NA DOENÇA  
DE PARKINSON


Trabalho de conclusão de curso apresentado ao Curso de Bacharelado em Sistemas de Informação do Instituto Federal de Alagoas - *Campus Maceió* para a obtenção do título de Bacharel em Sistemas de informação.

Aprovado em: 26/11/2023

**BANCA EXAMINADORA**



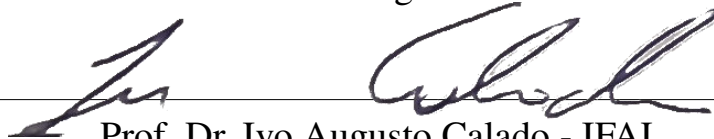
Prof. Dr. Leonardo Melo de Medeiros - IFAL (Orientador)



Prof. Dr. Arlyson Alves do Nascimento - IFAL (Coorientador)



Prof. Dr. Frederico Salgueiro Passos - IFAL



Prof. Dr. Ivo Augusto Calado - IFAL

Dedico este trabalho ao esforço de forjar uma jornada de aprendizado e crescimento. Mesmo diante das horas desafiadoras, persisti e encontrei forças para transpor obstáculos invisíveis. Que cada página deste trabalho seja um testemunho das dificuldades superadas e das conquistas alcançadas através do poder da resiliência.

## AGRADECIMENTOS

Gostaria de expressar meus mais sinceros agradecimentos a todos aqueles que desempenharam um papel verdadeiramente significativo na conclusão desta monografia.

À minha querida esposa, Emmanoely Alves, que esteve ao meu lado em todos os momentos, compreendendo as horas de ausência e oferecendo seu amor e apoio incondicional. Sua paciência e compreensão foram elementos cruciais que me permitiram dedicar-me plenamente a este trabalho.

Ao meu inspirador filhote, Nicolás Campos, cuja presença mesmo à distância sempre me impulsiona a buscar crescimento e a me desafiar a continuar avançando.

Agradeço imensamente a toda a minha família, meus pais e irmãos, cujo apoio inabalável e incentivo constante foram pilares fundamentais para que eu pudesse atingir este objetivo.

Aos meus respeitados professores, especialmente ao meu orientador, Leonardo Medeiros, que continuou acreditando neste projeto, e a Arlyson Nascimento, que tem estado ao meu lado desde o início desta jornada. Sua orientação experiente e compartilhamento de conhecimento foram absolutamente cruciais para minha formação acadêmica. Suas contribuições enriqueceram minha compreensão e serviram como faróis durante toda a minha trajetória de pesquisa.

Aos meus amigos e colegas, cujo apoio e incentivos estiveram sempre presentes nos momentos compartilhados, servindo como lembrete constante de que eu não estava sozinho nesta jornada desafiadora.

Ao IFAL-Campus Maceió, pelo apoio inestimável, e às empresas que me proporcionaram oportunidades de estágio, permitindo que meu desenvolvimento fosse completo ao unir teoria e prática.

A todos vocês, minha gratidão é profunda. Cada um de vocês desempenhou um papel único e significativo nesta jornada, e esta monografia é uma manifestação do amor, apoio e confiança que recebi de cada um. Obrigado por fazerem parte desta realização.

“Eu devia sorrir mais, abraçar meu pais, viajar o mundo e socializar. Nunca reclamar, só agradecer e tudo que vinher eu fiz por merecer ... Fácil de falar, difícil fazer!”

Supercombo

“It’s not always rainbows and butterflies, It’s compromise that moves us along.”

Maroon 5

“O sucesso é a soma de pequenos esforços repetidos dia após dia.”

Robert Collier

## RESUMO

A doença de Parkinson (DP) é caracterizada como um distúrbio neurodegenerativo e progressivo que afeta uma parte significativa da população idosa em todo o mundo. Os sintomas mais comuns da DP incluem problemas cognitivos, que tendem a se manifestar em estágios mais avançados da doença, ao contrário dos sintomas motores, que geralmente surgem no início da condição. A Escala Unificada de Classificação da Doença de Parkinson (MDS-UPDRS) é uma das principais ferramentas para o diagnóstico e monitoramento da doença de Parkinson em pacientes. Dentro da MDS-UPDRS III, que avalia a parte motora dos pacientes, encontra-se o teste de toque de dedos (FTT), utilizado para avaliar a bradicinesia e a rigidez de movimento. O FTT geralmente é administrado por um profissional de saúde que observa o paciente realizando o teste. No entanto, o uso da visão computacional pode oferecer uma alternativa mais eficaz, capturando com precisão as características do movimento. O objetivo deste estudo foi desenvolver um sistema de visão computacional capaz de adquirir dados dos movimentos finos dos dedos durante o FTT e, posteriormente, categorizar os estágios da doença de Parkinson usando máquina de vetores de suporte (SVM). Para este estudo, foi criado um algoritmo de visão computacional que registra os dados resultantes da abdução e adução dos movimentos das mãos durante o FTT, calculando a amplitude criada por esses movimentos. Utilizou-se um conjunto de dados composto por 532 vídeos de pacientes parkinsonianos e não parkinsonianos, classificados em quatro níveis de acordo com a MDS-UPDRS. Em seguida, foram realizados procedimentos de processamento dos sinais biomecânicos. Os resultados obtidos indicam que a aplicação da visão computacional no auxílio aos profissionais de saúde é promissora. A coleta de dados de movimento permite a criação de uma base de dados que pode ser empregada em modelos de aprendizado de máquina para prever o nível da doença do paciente com base na MDS-UPDRS. Além disso, foi desenvolvido um classificador binário para determinar em qual nível cada paciente se encaixa, utilizando um vetor de suporte de máquina (SVM) juntamente com a técnica de avaliação cruzada *leave-one-out*. Isso resultou em uma precisão de 73,3% ao utilizar todo o conjunto de dados disponível e de 76,6% ao usar apenas o FTT da mão direita.

**Palavras-chave:** visão computacional; doença de Parkinson; teste de toque de dedos.

## ABSTRACT

Parkinson's disease (PD) is characterized as a neurodegenerative and progressive disorder that affects a significant portion of the elderly population worldwide. The most common symptoms in PD include cognitive problems, which predominantly begin to appear in more advanced stages, unlike the motor symptoms that manifest at the onset of the disease. The Movement Disorder Society Unified Parkinson's Disease Rating Scale (MDS-UPDRS) is one of the assessments that aid in diagnosing and monitoring the levels of Parkinson's disease in patients. Within the MDS-UPDRS III, which assesses the motor aspects of patients, there is the Finger Tapping Test (FTT), used to assess bradykinesia and rigidity of movement. FTT is typically administered by a healthcare professional who observes the patient performing the test. However, the use of computer vision can provide a more effective alternative by accurately capturing the movement's characteristics. The aim of this study was to develop a computer vision system capable of acquiring data from fine finger movements during the FTT and subsequently classify Parkinson's disease levels according to the MDS-UPDRS. For this study, a computer vision algorithm was created to record data resulting from the abduction and adduction of hand movements during the FTT, calculating the amplitude generated by these movements. A dataset comprising 532 videos of both Parkinson's and non-Parkinson's patients, classified into four levels according to the MDS-UPDRS, was used. Subsequently, biomechanical signal processing procedures were conducted. The results obtained indicate that the use of computer vision in assisting healthcare professionals is promising. Data collection from movements allows for the creation of a database that can be used in machine learning models to predict the patient's disease level based on the MDS-UPDRS. Additionally, a binary classifier was developed to determine the level at which each patient falls, using a Support Vector Machine (SVM) along with the leave-one-out cross-validation technique. This resulted in an accuracy of 73.3% when using the entire available dataset and 76.6% when using only the right-hand FTT.

**Keywords:** computer vision; Parkinson's disease; finger tapping test

## LISTA DE ILUSTRAÇÕES

Figura 1 – Processo de extração e processamento dos movimentos. . . . .	23
Figura 2 – Processamento dos sinais biomecânicos. . . . .	24
Figura 3 – Diagrama de fluxo da RSL. . . . .	27
Figura 4 – Marcadores da biblioteca MediaPipe. Marcações dos pontos usados para captura dos dados 4, 0 e 8, marcados na figura em amarelo. Gerando triangulação e ângulo recuperado de $\alpha^\circ$ . . . . .	27
Figura 5 – Gráficos gerados inicialmente para análise. . . . .	30
Figura 6 – Fluxograma PRISMA da seleção da revisão sistemática de literatura. . . . .	47
Figura 7 – Gráfico dos trabalhos classificados por ano. . . . .	48

## LISTA DE TABELAS

Tabela 1 – Quantitativo de vídeos disponibilizados e utilizados. . . . .	31
Tabela 2 – Acurácia do FTT para cada nível na mão direita (R) e esquerda (L) utilizando o SVM e LOOCV . . . . .	36
Tabela 3 – Acurácia do FTT classificando os níveis <i>one vs one</i> dentro da MDS-UPDRS	36
Tabela 4 – Acurácia da classificação <i>one vs all</i> do FTT . . . . .	37
Tabela 5 – Pontuação possível para a avaliação da qualidade dos estudos. . . . .	46
Tabela 7 – Métricas utilizadas para classificar a DP. . . . .	48
Tabela 6 – Estudos selecionados para serem analisados conforme a proposta das QPs. .	49
Tabela 8 – Algoritmos utilizados para captura dos movimento no FTT. . . . .	49
Tabela 9 – Dados obtidos para a captura dos movimento no FTT. . . . .	50

## **LISTA DE ABREVIATURAS E SIGLAS**

DP	Doença de Parkinson
FTT	Finger Tapping Test
FoTT	Foot Tapping Test
MDS-UPDRS	Movement Disorder Society Unified Parkinson's Disease Rating Scale
RSL	Revisão Sistemática de Literatura
UPDRS	Unified Parkinson's Disease Rating Scale

## LISTA DE SÍMBOLOS

$\alpha$	Letra grega Alfa
$\alpha^\circ$	Ângulo de Alfa
$\theta$	Letra grega minúscula Teta

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
1.1	OBJETIVOS	15
<b>1.1.1</b>	<b><i>Objetivo geral</i></b>	<b>15</b>
<b>1.1.2</b>	<b><i>Objetivos específicos</i></b>	<b>15</b>
1.2	JUSTIFICATIVA	16
<b>2</b>	<b>DESENVOLVIMENTO</b>	<b>17</b>
2.1	A DOENÇA DE PARKINSON (DP)	17
<b>2.1.1</b>	<b>Sintomas</b>	<b>17</b>
<b>2.1.2</b>	<b>Prognóstico</b>	<b>18</b>
<b>2.1.3</b>	<b>MDS-UPDRS</b>	<b>18</b>
<b>2.1.4</b>	<b>Sintomas avaliados no FTT</b>	<b>18</b>
2.2	VISÃO COMPUTACIONAL EM MEDICINA	19
<b>2.2.1</b>	<b>Aplicações em Neurologia e Avaliação Motora</b>	<b>20</b>
2.3	SOFTWARE	20
<b>2.3.1</b>	<b>Python</b>	<b>20</b>
2.4	OPENCV	21
2.5	MEDIAPIPE	21
2.6	MACHINE LEARNING PARA CLASSIFICAÇÃO EM SAÚDE	21
<b>2.6.1</b>	<b>Aplicações de SVM em Diagnóstico Médico</b>	<b>21</b>
<b>2.6.2</b>	<b>Outros Algoritmos de Classificação em Neurologia</b>	<b>22</b>
<b>2.6.3</b>	<b>Métricas de Avaliação em Contextos Clínicos</b>	<b>22</b>
2.7	TRABALHOS RELACIONADOS	22
2.8	ARQUITETURA DO SOFTWARE	23
2.9	PROCESSAMENTO BIOMECANICOS	23
<b>3</b>	<b>METODOLOGIA</b>	<b>25</b>
3.1	REVISÃO SISTEMÁTICA DE LITERATURA (RSL)	25
<b>3.1.1</b>	<b>Questões de Pesquisa</b>	<b>25</b>
<b>3.1.2</b>	<b>Estratégia de Busca</b>	<b>25</b>
<b>3.1.3</b>	<b>Crítérios de Inclusão e Exclusão</b>	<b>26</b>
<b>3.1.4</b>	<b>Processo de Seleção</b>	<b>26</b>
<b>3.1.5</b>	<b>Análise dos Trabalhos Selecionados</b>	<b>26</b>
3.2	AQUISIÇÃO DOS DADOS ATRAVES DA VISÃO COMPUTACIONAL	27
<b>3.2.1</b>	<b>Características Extraídas</b>	<b>28</b>
<b>3.2.2</b>	<b>Pré-processamento dos Dados</b>	<b>29</b>
3.2.2.1	Normalização	29
3.2.2.2	Tratamento de Valores Ausentes	29
3.2.2.3	Filtragem de Sinais	29
<b>3.2.3</b>	<b>Tratamento dos Sinais</b>	<b>29</b>

3.2.4	<b>Validação dos sinais</b> . . . . .	<b>30</b>
3.3	BASE DE DADOS . . . . .	30
3.3.1	<b>Limpeza dos dados</b> . . . . .	<b>31</b>
3.4	CLASSIFICAÇÃO DOS DADOS . . . . .	32
3.4.1	<b>Parâmetros do SVM</b> . . . . .	<b>32</b>
3.4.2	<b>Máquinas de Vetores de Suporte (SVM)</b> . . . . .	<b>32</b>
3.4.3	<b>K-Fold</b> . . . . .	<b>33</b>
3.4.4	<b>Leave-One-Out Cross Validation (LOOCV)</b> . . . . .	<b>33</b>
<b>4</b>	<b>RESULTADOS OBTIDOS</b> . . . . .	<b>35</b>
4.1	USO DOS DADOS . . . . .	35
4.2	CLASSIFICAÇÃO . . . . .	35
4.2.1	<b>Análise Estatística</b> . . . . .	<b>37</b>
4.2.2	<b>Análise de Erros</b> . . . . .	<b>37</b>
4.2.3	<b>Comparação com Literatura</b> . . . . .	<b>38</b>
<b>5</b>	<b>CONCLUSÕES</b> . . . . .	<b>39</b>
5.1	TRABALHOS FUTUROS . . . . .	40
	<b>REFERÊNCIAS</b> . . . . .	<b>41</b>
	<b>APÊNDICE A – A EFICÁCIA DA ANÁLISE COMPUTACIONAL DO FINGER TAPPING TEST NA DETECÇÃO PRECOCE E MONITORAMENTO DE PARKINSON: UMA REVISÃO SISTEMÁTICA DE LITERATURA</b>	<b>43</b>

## 1 INTRODUÇÃO

A doença de Parkinson (DP) é um distúrbio neurodegenerativo que afeta principalmente a população idosa (ADAMS, 2017). Embora ainda não sejam conhecidos fatores específicos que indiquem o desenvolvimento da DP, podem-se observar sintomas característicos. Geralmente, os primeiros sintomas estão relacionados à coordenação motora, conhecidos como "sintomas motores cardinais", que incluem bradicinesia, rigidez, tremor e instabilidade postural (RAMDHANI *et al.*, 2018), seguidos por sintomas não motores, incluindo distúrbios psicológicos (JANKOVIC, 2008). Uma ferramenta que pode auxiliar na detecção da DP é a Escala Unificada de Classificação da Doença de Parkinson (MDS-UPDRS) (GOETZ *et al.*, 2008), que possui quatro divisões de testes para classificar a DP, sendo a terceira divisão relacionada a exames motores, denominada MDS-UPDRS III. Dentre esses testes, destacam-se o 26A e o 26B, que correspondem aos testes de toque de dedos (FTT).

O FTT é um teste realizado por um profissional especializado em testes indicados na MDS-UPDRS. No entanto, devido à natureza subjetiva da observação clínica, podem ocorrer falhas decorrentes de diversos fatores, tais como o nível de concentração e cansaço do aplicador do teste. O FTT consiste em realizar o movimento de adução e abdução entre os dedos polegar e indicador. Com esse teste, é possível avaliar a bradicinesia e a rigidez do movimento do paciente, indicando cinco níveis de gravidade, nos quais o nível 0 indica normalidade e o nível 4 indica gravidade severa dos sintomas (GOETZ *et al.*, 2008). O uso frequente desse teste pode auxiliar o profissional a prescrever dosagens mais específicas para cada paciente.

Atualmente, o uso de câmeras digitais está amplamente disponível para a maioria das pessoas. Nesse contexto, a visão computacional pode ser uma alternativa viável para resolver esse problema, uma vez que essa é a ciência que permite que um computador interprete e compreenda o ambiente ao seu redor por meio de processamento de imagem e dados visuais (BARLOW, 1983). Isso torna possível a criação de um sistema capaz de capturar os movimentos realizados no FTT, processá-los e gerar uma estimativa do grau de gravidade do paciente, o que pode ser de grande importância para a sociedade. Isso se deve ao baixo custo associado à utilização da visão computacional, o que contribuirá para o tratamento e a detecção precoce da DP. A visão computacional vem se desenvolvendo com o avanço de técnicas de software, podendo ser aplicada em diversos ambientes, incluindo a medicina por meio do estudo de imagens e vídeos (BARLOW, 1983). Tecnologias que auxiliam no desenvolvimento de estudos estão se tornando cada vez mais acessíveis, como é o caso da ferramenta de código aberto *MediaPipe*, que utiliza aprendizado de máquina para detectar partes do corpo (MediaPipe, 2023).

Para este trabalho, foi desenvolvido um algoritmo com uso de visão computacional para adquirir o posicionamento e movimento finos de três pontos nas mãos dos pacientes: a ponta do dedo indicador, a ponta do dedo polegar e a articulação metacarpofalangeana do dedo mínimo, formando assim uma triangulação. Com isso, são obtidos dados de angulação e tempo. Esses

dados são então representados graficamente, formando figuras de ondas que se tornam mais irregulares à medida que o nível de gravidade do paciente aumenta. Esses gráficos demonstram características como a frequência dos movimentos e as dificuldades na execução do movimento.

Para a realização dos testes, foi utilizada uma base de dados disponibilizada por YANG *et al.*(2022), que originalmente continha 611 vídeos, mas após filtragem, somente 87% puderam ser utilizados neste experimento. Alguns vídeos apresentavam baixa qualidade ou cortes após o tratamento realizado para a disponibilização dos vídeos.

Foi realizada a classificação dos níveis utilizando a técnica *Support Vector Machine* (SVM) com a abordagem *one vs one* para identificar a qual nível pertence o paciente. Além disso, foi empregada a avaliação cruzada com *Leave-One-Out Cross Validation* (LOOCV) para verificar o desempenho do modelo.

A técnica utilizada para detectar os pontos nas mãos durante o movimento do teste de toque de dedos (FTT) demonstrou ser viável para a geração de dados destinados a modelos de *Machine Learning*. O modelo SVM obteve uma acurácia média de 73,3% na abordagem *one vs one*, enquanto na técnica *one vs all* apresentou 71,7%. A validação cruzada LOOCV indicou que o desempenho do modelo é satisfatório, com uma diferença de apenas 1,7% na classificação em comparação com o modelo original.

## 1.1 OBJETIVOS

O objetivo principal deste projeto é desenvolver experimentos com visão computacional capaz de adquirir características dos movimentos motores finos das mãos, com enfoque no *Finger Tapping Test (FTT)*, para avaliação de pacientes com doença de Parkinson. O FTT é uma técnica utilizada para avaliar habilidades motoras finas, mensurando a velocidade e regularidade dos movimentos dos dedos. Com a utilização da visão computacional, busca-se obter uma análise mais objetiva e precisa dos movimentos, possibilitando um diagnóstico mais acurado da doença de Parkinson e um tratamento mais personalizado para cada paciente.

### 1.1.1 *Objetivo geral*

O objetivo geral do trabalho é desenvolver um algoritmo que utilize visão computacional para adquirir características dos movimentos motores finos das mãos, com foco no teste de toque de dedos (FTT), a fim de avaliar a doença de Parkinson (DP) dentro da MDS-UPDRS III.

### 1.1.2 *Objetivos específicos*

- Desenvolver um algoritmo que capture os movimentos finos dos dedos durante o FTT e os transforme em dados quantitativos.
- Avaliar a precisão e a eficácia do sistema de visão computacional em comparação com outras técnicas de avaliação de habilidades motoras finas.

- Identificar padrões de movimento característicos indicados na escala MDS-UPDRS III.
- Realizar classificação entre os níveis de DP no FTT.

## 1.2 JUSTIFICATIVA

A avaliação subjetiva do FTT por profissionais de saúde apresenta limitações que podem comprometer a precisão diagnóstica e o acompanhamento da evolução da doença de Parkinson. A natureza observacional do teste tradicional introduz variabilidade inter-avaliador, onde diferentes profissionais podem interpretar os mesmos movimentos de forma distinta, dependendo de fatores como experiência clínica, nível de concentração e cansaço do examinador.

A implementação de sistemas automatizados baseados em visão computacional pode oferecer uma alternativa objetiva e quantitativa, reduzindo a variabilidade inter-avaliador e permitindo um monitoramento mais preciso e contínuo dos pacientes. Além disso, o baixo custo associado à utilização de câmeras digitais e ferramentas de código aberto torna essa abordagem acessível para diferentes contextos clínicos, contribuindo para a democratização do acesso a ferramentas de avaliação objetiva.

O impacto social e econômico da doença de Parkinson é significativo, afetando mais de 6 milhões de pessoas em todo o mundo. A detecção precoce e o monitoramento preciso da evolução da doença são essenciais para otimizar o tratamento e melhorar a qualidade de vida dos pacientes. Portanto, o desenvolvimento de ferramentas objetivas e acessíveis para avaliação dos sintomas motores representa uma contribuição relevante para a área de saúde.

Este trabalho contribui para o avanço do conhecimento na área ao propor uma metodologia automatizada para avaliação do FTT utilizando visão computacional, oferecendo uma alternativa viável e objetiva para auxiliar profissionais de saúde no diagnóstico e acompanhamento de pacientes com doença de Parkinson.

## 2 DESENVOLVIMENTO

Este capítulo tem como objetivo fornecer ao leitor uma visão geral das principais áreas em que este trabalho se baseia. Mais especificamente, é apresentada uma explicação sobre a doença de Parkinson, suas fases e seus sintomas motores. Além disso, mostra-se como o FTT pode avaliar a DP e como um sistema de visão computacional pode auxiliar na classificação do paciente.

### 2.1 A DOENÇA DE PARKINSON (DP)

A doença de Parkinson é um distúrbio neurodegenerativo que afeta principalmente os neurônios produtores de dopamina (também conhecidos como "neurônios dopaminérgicos") na região denominada "substância negra" do cérebro (FOUNDATION, 2022). Fatores desconhecidos contribuem para o desenvolvimento da DP, porém alguns casos são hereditários e outros são decorrentes de uma confluência de fatores genéticos e ambientais ((NIH), 2022).

Caracterizada com uma doença progressiva que afeta mais de 6 milhões de pessoas em todo o mundo e cerca de 2% das pessoas aos 65 anos (ADAMS, 2017). Inicialmente pode-se ser observado por uma série de sintomas motores cardinais, incluindo bradicinesia, rigidez, tremor e instabilidade postural (RAMDHANI *et al.*, 2018), sendo estes os sintomas mais comuns no início da DP. Uma variedade de sintomas motores e não motores são causados pela perda de neurônios produtores de dopamina (ADAMS, 2017).

#### 2.1.1 Sintomas

Segundo (JANKOVIC, 2008) pessoas com DP podem ter até 6 vezes mais chance de demência em relação a pessoas normais, onde cerca de 84% dos pacientes apresentam algum nível de declínio cognitivo. Delírios também são frequentes em estágios mais avançados da DP, podendo ocorrer alucinações não visuais (auditivas, táteis e olfativas) junto com alucinações visuais (CREESE *et al.*, 2017).

Na DP, os sinais não motores mais comuns são os distúrbios neuropsiquiátricos, que incluem distúrbios de cognição, humor, sono, comportamento e pensamento. Geralmente, esses sinais aparecem após os sinais motores.

Um dos sintomas motores mais comuns da doença é um tremor lento que ocorre na mão quando está em repouso. Esse tremor desaparece durante o movimento voluntário do membro afetado. Inicialmente, esse tremor é observado em apenas uma das mãos, mas com o avanço da doença, pode se estender para a outra mão. (JANKOVIC, 2008).

A bradicinesia, sendo um sintoma encontrado nos pacientes com DP e obrigatório no diagnóstico, é descrita como um movimento lento associado à redução do volume e/ou velocidade do movimento (VIGNOUD *et al.*, 2022). Este sintoma torna o portador incapaz de

realizar tarefas comuns diárias, pois prejudica a funcionalidade de movimento simultâneo e sequencial. A avaliação formal exige que as pessoas façam movimentos repetitivos das mãos e dos pés.

A rigidez, caracterizada como uma contração contínua e excessiva dos músculos, pode estar associada a dor nas articulações, podendo a dor ser um sintoma inicial da DP. Afeta inicialmente as extremidades do corpo, mas se espalha conforme a progressão da doença (JANKOVIC, 2008).

### **2.1.2 Prognóstico**

A doença de Parkinson sempre progride com o tempo. A métrica mais utilizada para um estudo clínico é a escala unificada de classificação da doença de Parkinson (UPDRS) (GOETZ *et al.*, 2008), que é um método de classificação de gravidade. Uma versão modificada conhecida como MDS-UPDRS também é usada ocasionalmente. Tanto o método de dimensionamento mais tradicional conhecido como escala de Hoehn e Yahr (publicado pela primeira vez em 1967) quanto uma escala relacionada conhecida como escala modificada de Hoehn e Yahr têm sido frequentemente empregadas.

### **2.1.3 MDS-UPDRS**

Desenvolvida originalmente na década de 1980, a escala é uma avaliação abrangente composta por 50 perguntas sobre sintomas motores e não motores associados à doença de Parkinson (DP). Inicialmente, ela foi dividida em quatro categorias (GOETZ *et al.*, 2008):

- I - Experiências não motoras da vida diária;
- II - Experiências motoras da vida diária;
- III - Exame motor;
- IV - Complicações motoras;

Cada pergunta está vinculada a cinco opções de resposta, que estão relacionadas a termos clínicos amplamente aceitos. Essas opções são as seguintes: 0 = normal, 1 = leve, 2 = moderado, 3 = grave e 4 = muito grave. Após cada descritor clínico, segue um pequeno texto que descreve os critérios para cada resposta.

### **2.1.4 Sintomas avaliados no FTT**

O FTT (teste de toque dos dedos) faz parte da categoria III da MDS-UPDRS, especificamente nos itens 26<sub>A</sub> (mão direita) e 26<sub>B</sub> (mão esquerda) (GOETZ *et al.*, 2008). Esse teste está associado à avaliação da ataxia e, na doença de Parkinson (DP), mede a bradicinesia.

Em pacientes com DP, o teste de toque dos dedos foi selecionado porque o padrão de movimento dos dedos pode ser mais gravemente prejudicado em comparação com os movimentos

de abertura e fechamento da mão ou pronação e supinação da mão, que são avaliados na seção motora da MDS-UPDRS.

Para a classificação do FTT, segue-se o seguinte procedimento segundo a MDS-UPDRS III (GOETZ *et al.*, 2008):

“Instruções ao examinador: Cada mão é testada separadamente. Demonstre a tarefa, mas não continue a executá-la enquanto o paciente estiver sendo testado. Instrua o paciente a bater o dedo indicador no polegar 10 vezes o mais rápido e o maior possível. Avalie cada lado separadamente, avaliando velocidade, amplitude, hesitações, paradas e diminuição da amplitude.

- **0 - Normal:** Sem problemas;
- **1 - Leve:** Qualquer um dos seguintes:
  - O ritmo regular é quebrado com uma ou duas interrupções ou hesitações do movimento de batidas;
  - Leve lentidão;
  - A amplitude diminui próximo ao final dos 10 toques;
- **2 - Ligeiramente Moderado:** Qualquer um dos seguintes:
  - 03 a 05 interrupções durante o batimento;
  - Lentidão moderada;
  - A amplitude diminui no meio da sequência de 10 toques.
- **3 - Moderado:** Qualquer um dos seguintes
  - Mais de 5 interrupções durante a batida ou pelo menos uma parada mais longa (congelamento) em movimento contínuo;
  - Lentidão moderada;
  - A amplitude diminui a partir do 1º toque.
- **4 - Grave:** Não consegue ou mal consegue executar a tarefa devido a lentidão, interrupções ou decréscimos.

## 2.2 VISÃO COMPUTACIONAL EM MEDICINA

Segundo a definição de (BARLOW, 1983), a visão computacional é a tecnologia e ciência responsável pela forma como um computador enxerga o mundo ao seu redor, interpretando ima-

gens em três dimensões para imagens em duas dimensões. Ela extrai informações significativas a partir de imagens capturadas por câmeras de vídeo, sensores, scanners e outros dispositivos.

### **2.2.1 Aplicações em Neurologia e Avaliação Motora**

A visão computacional tem sido amplamente aplicada em contextos médicos, especialmente na área de neurologia e avaliação motora. Em neurologia, essas técnicas têm sido utilizadas para análise de movimentos, detecção de anormalidades motoras e monitoramento de doenças neurodegenerativas.

No contexto da avaliação motora, a visão computacional oferece vantagens significativas em relação aos métodos tradicionais de observação clínica. Entre essas vantagens, destacam-se: (1) objetividade na avaliação, eliminando a subjetividade inerente à observação humana; (2) capacidade de capturar e quantificar movimentos sutis que podem não ser perceptíveis ao olho humano; (3) possibilidade de análise em tempo real ou posterior, permitindo revisão detalhada dos movimentos; (4) padronização do processo de avaliação, reduzindo variabilidade inter-avaliador.

No entanto, existem limitações que devem ser consideradas: (1) dependência da qualidade da captura (iluminação, resolução, ângulo); (2) necessidade de calibração adequada dos sistemas; (3) possíveis erros de detecção em condições adversas; (4) custos iniciais de implementação, embora reduzidos com tecnologias atuais.

Comparando com outras técnicas de avaliação objetiva, como sensores inerciais (IMU) e sistemas de captura de movimento (motion capture), a visão computacional apresenta a vantagem de ser não invasiva e não requerer equipamentos adicionais acoplados ao paciente, além de utilizar equipamentos amplamente disponíveis (câmeras digitais).

## **2.3 SOFTWARE**

### **2.3.1 Python**

Neste experimento, foi utilizada a linguagem Python, que é uma linguagem de programação de alto nível, interpretada e orientada a objetos. Foi criada em 1991 por Guido van Rossum e tem sido amplamente utilizada desde então (Python Software Foundation, 2023).

Uma das principais características do Python é a sua simplicidade e legibilidade, tornando a linguagem fácil de aprender e utilizar. Além disso, Python tem uma vasta biblioteca padrão e uma comunidade ativa que oferece uma ampla variedade de pacotes para diversas finalidades, como análise de dados, machine learning, web development, entre outros (Python Software Foundation, 2023).

## 2.4 OPENCV

OpenCV (Open Source Computer Vision) é uma biblioteca de visão computacional e aprendizado de máquina de código aberto e ferramentas de processamento de imagens (OpenCV, 2023). Ela fornece uma coleção de algoritmos para reconhecimento de objetos, rastreamento de movimento, calibração de câmera, reconhecimento facial, análise de vídeo, entre outras funções (BRADSKI; KAEHLER, 2008). A biblioteca é escrita em C++, mas também possui interfaces para Python, Java, MATLAB e outras linguagens de programação (SOLEM, 2012).

A biblioteca OpenCV é amplamente utilizada em muitos campos, incluindo robótica, automação industrial, segurança e medicina, entre outros. É uma ferramenta poderosa para análise em tempo real de imagens e vídeos, tornando-se uma opção popular entre desenvolvedores e pesquisadores (OpenCV, 2023).

## 2.5 MEDIPIPE

A biblioteca MediaPipe é uma ferramenta de processamento de mídia multiplataforma desenvolvida pelo Google que oferece um conjunto de soluções para análise de vídeo e áudio. É uma ferramenta poderosa para desenvolvedores interessados em incorporar recursos de visão computacional em seus aplicativos (MediaPipe, 2023). Ela é capaz de realizar diversas tarefas, como detecção de poses, rastreamento facial, detecção de objetos, entre outras.

Uma das funcionalidades mais populares da biblioteca é o pacote para identificação de mãos, que viabiliza o reconhecimento em tempo real das mãos em um fluxo de vídeo. A detecção de mãos é uma tarefa desafiadora na área de visão computacional devido à alta variabilidade na aparência das mãos e à sua grande capacidade de movimento. No entanto, o pacote de reconhecimento de mãos da MediaPipe utiliza um algoritmo de aprendizado profundo altamente eficiente para detectar com precisão as mãos em um fluxo de vídeo (ZHANG *et al.*, 2020).

## 2.6 MACHINE LEARNING PARA CLASSIFICAÇÃO EM SAÚDE

### 2.6.1 Aplicações de SVM em Diagnóstico Médico

As Máquinas de Vetores de Suporte (SVM) têm sido amplamente utilizadas em diagnóstico médico devido à sua capacidade de lidar com problemas de classificação binária e multiclasse, além de sua eficácia mesmo com conjuntos de dados relativamente pequenos. Em contextos clínicos, o SVM tem sido aplicado para classificação de imagens médicas, análise de sinais biológicos e diagnóstico assistido por computador.

As principais vantagens do SVM para aplicações médicas incluem: (1) capacidade de trabalhar com dados de alta dimensionalidade; (2) eficácia mesmo com amostras limitadas; (3) robustez a ruídos nos dados; (4) interpretabilidade relativa através dos vetores de suporte.

## 2.6.2 Outros Algoritmos de Classificação em Neurologia

Além do SVM, outros algoritmos de aprendizado de máquina têm sido utilizados em neurologia para classificação e diagnóstico. Entre eles, destacam-se: (1) Redes Neurais Artificiais (RNA), que têm sido aplicadas para análise de padrões complexos em dados neurológicos; (2) Random Forest, utilizado para classificação de múltiplas características motoras; (3) K-Nearest Neighbors (KNN), aplicado em problemas de classificação de movimentos; (4) Regressão Logística, utilizada para análise de fatores de risco e diagnóstico.

A escolha do algoritmo depende de diversos fatores, incluindo o tamanho do conjunto de dados, a complexidade do problema, a necessidade de interpretabilidade e os recursos computacionais disponíveis.

## 2.6.3 Métricas de Avaliação em Contextos Clínicos

Em contextos clínicos, além da acurácia, outras métricas são importantes para avaliar o desempenho de modelos de classificação. Entre elas, destacam-se: (1) Sensibilidade (recall), que mede a capacidade do modelo de identificar corretamente casos positivos; (2) Especificidade, que mede a capacidade de identificar corretamente casos negativos; (3) Precisão, que indica a proporção de predições positivas que são realmente corretas; (4) F1-score, que combina precisão e recall em uma única métrica; (5) Área sob a curva ROC (AUC-ROC), que avalia a capacidade discriminativa do modelo.

Essas métricas são especialmente importantes em contextos médicos, onde falsos negativos e falsos positivos podem ter implicações clínicas significativas.

## 2.7 TRABALHOS RELACIONADOS

Diversos trabalhos têm explorado o uso de visão computacional e técnicas de aprendizado de máquina para avaliação da doença de Parkinson, especialmente focando no Finger Tapping Test (FTT) e outros testes da MDS-UPDRS.

YANG *et al.*(2022) desenvolveram um pipeline automático para avaliação da severidade motora da doença de Parkinson utilizando FTT e estabilidade postural, obtendo resultados promissores na classificação dos níveis da MDS-UPDRS. NUNES *et al.*(2021) utilizaram técnicas de visão computacional para análise de movimentos de mãos em pacientes com Parkinson, demonstrando a viabilidade da abordagem. VIGNOUD *et al.*(2021) exploraram o uso de sensores e visão computacional para avaliação de bradicinesia em pacientes parkinsonianos.

Os principais diferenciais e contribuições do presente trabalho em relação aos trabalhos anteriores incluem: (1) utilização de uma abordagem específica de triangulação de pontos para captura de características do movimento; (2) análise comparativa entre diferentes estratégias de classificação (one vs one e one vs all); (3) avaliação detalhada considerando separadamente mão direita e esquerda; (4) utilização de validação cruzada LOOCV para avaliação robusta do modelo.

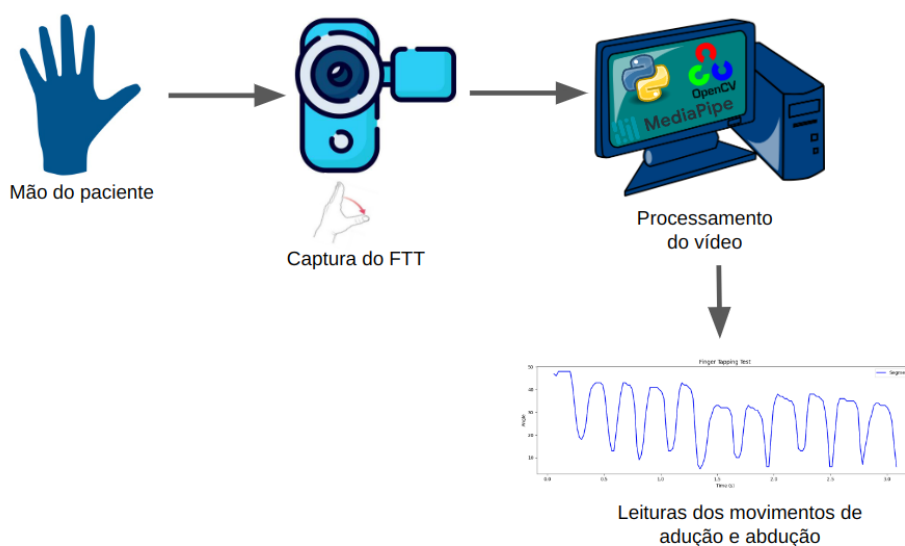
As principais limitações identificadas em trabalhos anteriores incluem: (1) dependência de equipamentos especializados ou sensores acoplados ao paciente; (2) necessidade de ambientes controlados para captura; (3) limitações na generalização dos resultados devido a conjuntos de dados pequenos ou desbalanceados; (4) falta de comparação sistemática entre diferentes abordagens de classificação.

## 2.8 ARQUITETURA DO SOFTWARE

O software consiste na captura do movimento realizado no FTT, uma mão por vez. A captura é realizada através da webcam vinculada ao computador ou através de importação do vídeo vindo de outro dispositivo.

O vídeo capturado é processado pelo algoritmo que foi desenvolvido em Python junto com as bibliotecas *OpenCV* e *MediaPipe*. O papel do *OpenCV* é realizar o tratamento do vídeo, e a biblioteca *MediaPipe* com o pacote *hands* é usada para detectar as poses realizadas pelas mãos, demonstrada na Figura 1.

Figura 1 – Processo de extração e processamento dos movimentos.

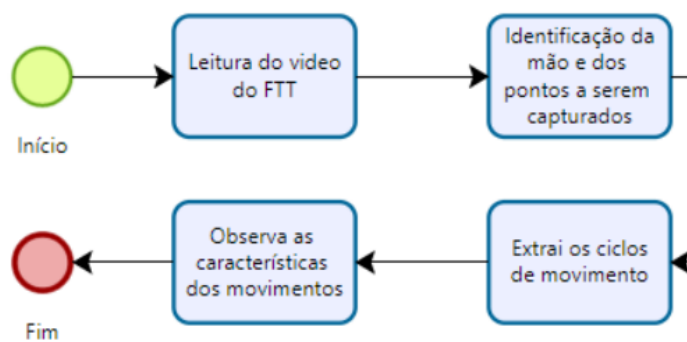


Fonte: Elaborado pelos autores

## 2.9 PROCESSAMENTO BIOMECANICOS

O módulo de Processamento de Dados Biomecânicos é responsável por ler o vídeo do teste de toque de dedos, identificar os ciclos de movimento e extrair posteriormente os vetores de características, como demonstrado na Figura 2.

Figura 2 – Processamento dos sinais biomecânicos.



Fonte: Elaborado pelos autores

### 3 METODOLOGIA

Este trabalho trata-se de uma pesquisa exploratória, na qual buscamos proporcionar uma maior compreensão do problema em estudo, tornando-o mais explícito e possibilitando a formulação de hipóteses. O objetivo é o aprimoramento das ideias envolvidas no estudo e a descoberta de intuições relacionadas à proposta (GIL, 2002).

A pesquisa exploratória desempenha um papel fundamental ao proporcionar explicações para fenômenos que inicialmente podem não ser aceitos por outros pesquisadores, mesmo quando evidências são apresentadas. Além disso, ela abre caminho para a descoberta de novos fenômenos, bem como para a formulação de novas ideias e hipóteses. Essa abordagem possibilita uma visão mais ampla e flexível na investigação científica.

#### 3.1 REVISÃO SISTEMÁTICA DE LITERATURA (RSL)

Foi inicialmente realizada uma RSL<sup>1</sup> com o intuito de avaliar o uso do FTT como ferramenta no auxílio da detecção de doenças motoras, como a doença de Parkinson, e estudos de análise computacional em relação ao teste. A RSL foi conduzida seguindo metodologia sistemática para garantir reprodutibilidade e rigor científico.

Para auxiliar na condução da RSL, foi utilizada a ferramenta *Parsifal*, uma plataforma web que facilita o processo de revisão sistemática, permitindo o gerenciamento de estudos, aplicação de critérios de inclusão e exclusão, e documentação do processo de seleção.

##### 3.1.1 Questões de Pesquisa

Como questões a serem investigadas, foi indagado sobre: (1) a eficácia do FTT enquanto teste de detecção de Parkinson; (2) a precisão do teste como ferramenta diagnóstica; (3) a viabilidade de uma análise computacional aplicada no FTT.

##### 3.1.2 Estratégia de Busca

Como base da pesquisa, foram utilizadas as bases de dados PubMed e Scopus, escolhidas por serem reconhecidas como principais bases de dados para pesquisas na área de saúde e ciências. A escolha dessas bases garante ampla cobertura da literatura científica relevante.

A string de busca utilizada foi: ("*Parkinson*"OR "*Parkinson's disease*") AND ("*Finger Tapping Test*"OR "*FTT*") AND ("*Analysis*"OR "*Computational*"OR "*Computer-assisted*") AND ("*Algorithms*"OR "*Accuracy*"OR "*Machine learning*"OR "*Diagnosis*"OR "*Early detection*"OR "*Monitoring*"OR "*Sensitivity*"OR "*Specificity*"). Esta string foi aplicada em ambas as bases, utilizando como filtro trabalhos publicados entre os anos de 2018 a 2023, garantindo que apenas trabalhos recentes fossem considerados.

<sup>1</sup> RSL completa encontra-se no APÊNDICE A

### **3.1.3 Critérios de Inclusão e Exclusão**

Foram estabelecidos critérios claros de inclusão e exclusão para garantir a qualidade e relevância dos estudos selecionados:

#### **Critérios de Inclusão:**

- Estudos que utilizam FTT para avaliação de doença de Parkinson;
- Trabalhos que aplicam técnicas computacionais ou de análise automatizada;
- Estudos publicados em inglês, português ou espanhol;
- Artigos completos disponíveis para análise.

#### **Critérios de Exclusão:**

- Estudos que não utilizam FTT como método de avaliação;
- Trabalhos que não aplicam técnicas computacionais;
- Artigos de revisão sem dados originais;
- Estudos com população não relacionada à doença de Parkinson;
- Trabalhos duplicados entre as bases de dados.

### **3.1.4 Processo de Seleção**

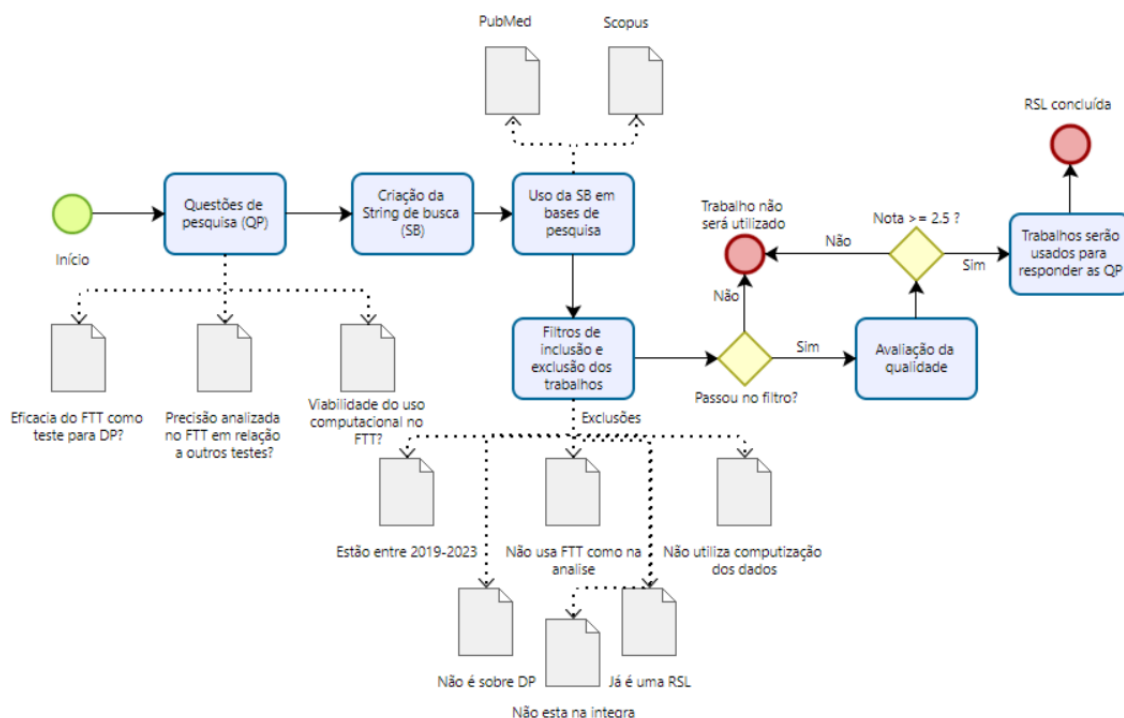
Foram levantados 134 estudos nas bases de dados consultadas. Após remoção de duplicatas, os títulos e resumos foram analisados para verificação de elegibilidade. Os estudos que atenderam aos critérios iniciais tiveram seus textos completos analisados. A partir deste processo, foi realizada uma seleção rigorosa de critérios de inclusão e exclusão, resultando em quatro (04) trabalhos que correspondiam a todos os critérios estabelecidos.

Na Figura 3, pode-se ver um detalhamento de como foi construída a RSL, incluindo o fluxo de seleção dos estudos.

### **3.1.5 Análise dos Trabalhos Selecionados**

Os quatro trabalhos selecionados foram analisados criticamente, identificando: (1) metodologias utilizadas; (2) técnicas de análise computacional aplicadas; (3) resultados obtidos; (4) limitações identificadas; (5) contribuições para a área. Esta análise permitiu identificar lacunas na literatura e justificar a necessidade do presente trabalho.

Figura 3 – Diagrama de fluxo da RSL.

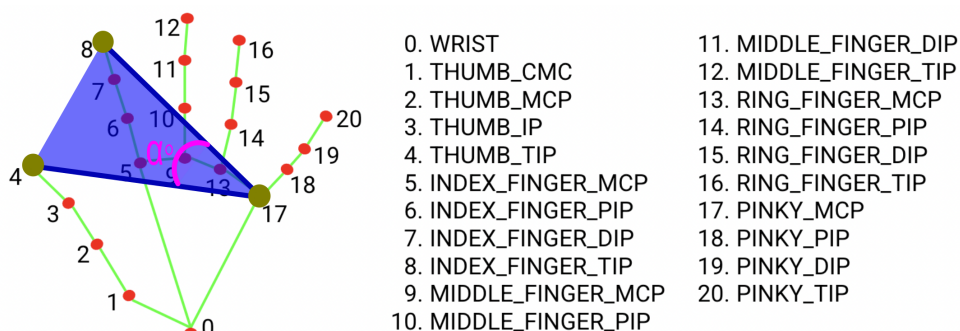


Fonte: Elaborado pelos autores

### 3.2 AQUISIÇÃO DOS DADOS ATRAVES DA VISÃO COMPUTACIONAL

Após o processamento, é gerada uma tabela com as colunas de *tempo* (tempo decorrido do vídeo) e *ângulo*, gerado a partir dos vértices entre a ponta dos dedos indicador (8 - Index finger tip) e polegar (4 - Thumb tip), juntamente com a articulação metacarpofalangeana do dedo mínimo (17 - Pinky MCP), representados na Figura 4.

Figura 4 – Marcadores da biblioteca MediaPipe. Marcação dos pontos usados para captura dos dados 4, 0 e 8, marcados na figura em amarelo. Gerando triangulação e ângulo recuperado de  $\alpha^\circ$



Fonte: Adaptado de GOOGLE (2023)

Para chegar ao ângulo  $\alpha^\circ$  (3.5), foram obtidos frame a frame os pontos em duas dimensões

(2D) da localização de cada pixel dos pontos x e y de P4, P8 e P17 (3.1).

$$P_4 = (x_4, y_4); P_8 = (x_8, y_8); P_{17} = (x_{17}, y_{17}) \quad (3.1)$$

Com isso, é possível criar dois vetores (3.2)(3.3), nos quais pode-se calcular o radiano de  $\theta$  (3.4) através do arco cosseno do produto escalar entre os vetores dividido pelo produto dos módulos dos vetores. Por fim, faz-se o quociente de 180 por  $\pi$  multiplicando o radiano de  $\theta$  encontrado.

$$\vec{V}_1 = P_4 - P_{17} = (x_4 - x_{17}, y_4 - y_{17}) \quad (3.2)$$

$$\vec{V}_2 = P_8 - P_{17} = (x_8 - x_{17}, y_8 - y_{17}) \quad (3.3)$$

$$\theta = \arccos \left( \frac{\vec{V}_1 \cdot \vec{V}_2}{\|\vec{V}_1\| \cdot \|\vec{V}_2\|} \right) \quad (3.4)$$

$$\alpha^\circ = \left( \frac{180}{\pi} \right) \cdot \theta \quad (3.5)$$

### 3.2.1 Características Extraídas

Além dos dados de ângulo e tempo obtidos através da triangulação, foram extraídas diversas características dos sinais biomecânicos para utilização no modelo de classificação. Essas características foram selecionadas com base na literatura sobre avaliação motora e análise de movimentos em pacientes com doença de Parkinson.

As principais características extraídas incluem:

- **Ângulo médio:** Média dos valores de ângulo ao longo do teste;
- **Amplitude do movimento:** Diferença entre o maior e menor valor de ângulo;
- **Frequência de toque:** Número de toques realizados por segundo;
- **Variabilidade do ângulo:** Desvio padrão dos valores de ângulo;
- **Regularidade do movimento:** Coeficiente de variação do sinal;
- **Duração dos ciclos:** Tempo médio entre toques consecutivos;
- **Taxa de decaimento:** Redução da amplitude ao longo do teste (indicador de fadiga);
- **Número de hesitações:** Identificação de pausas ou interrupções no movimento.

A escolha dessas características foi fundamentada na escala MDS-UPDRS, que avalia velocidade, amplitude, hesitações, paradas e diminuição da amplitude durante o FTT. Essas características capturam aspectos quantitativos dos movimentos que são relevantes para a classificação dos níveis de gravidade da doença.

### 3.2.2 Pré-processamento dos Dados

Antes da extração das características, os sinais brutos foram submetidos a um processo de pré-processamento para garantir qualidade dos dados e melhorar o desempenho do modelo de classificação.

#### 3.2.2.1 Normalização

Os dados de ângulo foram normalizados para garantir que diferentes vídeos, capturados em condições variadas, possam ser comparados adequadamente. A normalização foi realizada utilizando a fórmula:

$$\theta_{normalizado} = \frac{\theta - \theta_{min}}{\theta_{max} - \theta_{min}} \quad (3.6)$$

onde  $\theta_{min}$  e  $\theta_{max}$  são os valores mínimo e máximo de ângulo para cada vídeo individual.

#### 3.2.2.2 Tratamento de Valores Ausentes

Em casos onde a detecção dos pontos falhou temporariamente (devido a obstruções, saída do campo de visão ou problemas de iluminação), os valores ausentes foram tratados utilizando interpolação linear entre os pontos válidos adjacentes. Vídeos com mais de 40% de dados ausentes foram descartados, conforme descrito na seção de limpeza de dados.


#### 3.2.2.3 Filtragem de Sinais

Para reduzir ruídos e melhorar a qualidade do sinal, foi aplicado um filtro passa-baixa utilizando média móvel com janela de 5 frames. Este filtro suaviza o sinal sem perder informações importantes sobre o movimento, mantendo as características essenciais para a classificação.

### 3.2.3 Tratamento dos Sinais

Ao capturar os sinais produzidos e realizar uma análise inicial, podem-se observar gráficos que representam o movimento produzido, destacando o movimento de onda gerado pelos pontos contínuos da aquisição dos movimentos. A linha ondulada mostrada na Figura 5 representa o processamento dos dados obtidos em um instante de tempo específico, no qual cada segundo é composto por uma média de 70 pontos no eixo cartesiano.

Figura 5 – Gráficos gerados inicialmente para análise.



Fonte: Elaborado pelos autores

Conforme descrito na MDS-UPDRS sobre o FTT, o teste deve ser realizado ao menos três vezes por cada mão, a fim de obter uma melhor classificação pelo examinador. Para a proposta deste trabalho, também é levada em consideração a repetição do teste, pois, como observado na Figura 5, cada sequência de teste pode resultar em gráficos diferenciados, mesmo que com características semelhantes, quando feita a sua análise.

### 3.2.4 Validação dos sinais

O algoritmo projetado procura o objeto (mão) para poder extrair as informações, mas, por usar somente o sensor da câmera, podem ocorrer problemas como a falta de luminosidade do local, a baixa resolução da câmera, falta de foco e mau posicionamento do objeto de estudo.

Caso ocorra algum problema com a extração dos dados, o sistema poderá acusar erro no processamento e será necessária a realização de novo procedimento até que ocorra de forma eficiente a aquisição dos dados para análise.

## 3.3 BASE DE DADOS

Através da colaboração com a pesquisa *PDMotor* realizada por YANG *et al.* (2022) em seu artigo intitulado *Automatic detection pipeline for assessing the motor severity of Parkinson's disease in finger tapping and postural stability*, conseguimos obter vídeos de pacientes reais com DP. Foi necessário enviar um termo de responsabilidade para ter acesso e uso do banco de dados.

O banco de dados obtido consiste em um total de 611 vídeos de 5 segundos de duração cada, sendo 368 do FFT da mão esquerda e 243 da mão direita como mostra a Tabela 1. Segundo o autor, os números são divergentes porque alguns pacientes não registraram todas as ações. Esses vídeos foram gravados com pacientes do *Beijing Tiantan Hospital*.

Os vídeos enviados apresentam qualidade diferente do que foi mencionado no artigo original, além de ocorrerem falhas na reprodução. Em alguns vídeos, foi aplicado um tratamento

Tabela 1 – Quantitativo de vídeos disponibilizados e utilizados.

<b>MÃO - NÍVEL DE DP</b>	<b>QUANTIDADE TOTAL</b>	<b>QUANTIDADE POS TRATAMENTO</b>
Direita - 0	33	29
Direita - 1	113	99
Direita - 2	88	80
Direita - 3	9	9
<b>TOTAL DIREITA</b>	<b>243</b>	<b>217</b>
Esquerda - 0	66	52
Esquerda - 1	134	115
Esquerda - 2	141	121
Esquerda - 3	27	27
<b>TOTAL ESQUERDA</b>	<b>368</b>	<b>315</b>
<b>TOTAL GERAL</b>	<b>611</b>	<b>532</b>

Fonte: Elaborado pelos autores

para ocultar o rosto do paciente, o que conseqüentemente acabou ocultando o movimento do FTT. Os vídeos também apresentam diversos ângulos da mão do paciente em relação ao sensor de captura, o que atrapalhou a criação da triangulação dos pontos. Com isso, apenas 87,07% dos vídeos puderam ser utilizados neste estudo.

### 3.3.1 Limpeza dos dados

Através dos gráficos gerados, foi possível observar que alguns vídeos apresentavam problemas de processamento. Os problemas mais comuns incluíam arquivos de vídeo corrompidos, a não detecção dos pontos nos dedos devido a alguma obstrução ou saída do campo de visão da câmera, e ângulos da mão em relação à câmera que dificultavam a visualização dos pontos a serem coletados. Um caso curioso foi a identificação de um vídeo em que a mão do paciente estava coberta por uma luva, nesse caso, nossa visão computacional não conseguiu identificar o objeto de análise. Essas observações destacam a importância de lidar com essas variabilidades e desafios ao trabalhar com visão computacional em aplicações médicas.

Realizando a observação dos gráficos do movimento biomecânico, foi possível identificar quais vídeos do *dataset* apresentavam falhas. Foram descartados vídeos que tinham mais de 40% de comprometimento, ou seja, aqueles que tinham a partir de 2 segundos de falha, considerando que todos os vídeos do dataset contêm aproximadamente 5 segundos. Esse critério de descarte parece razoável para garantir a qualidade dos dados utilizados na análise e no treinamento do modelo.

### 3.4 CLASSIFICAÇÃO DOS DADOS

Para classificar os dados, foi utilizado o algoritmo de aprendizado supervisionado SVM (*Support Vector Machine*), que é amplamente utilizado para classificar dados em grupos diferentes (COUTINHO, 2019). Além disso, o SVM é escolhido por ser um algoritmo simples e de baixo custo computacional, tornando-o uma escolha eficaz para a tarefa de classificação (GANDHI, 2018).

#### 3.4.1 Parâmetros do SVM

O SVM foi configurado com os seguintes parâmetros:

**Kernel:** Foi utilizado o kernel RBF (Radial Basis Function), também conhecido como kernel gaussiano, devido à sua capacidade de lidar com problemas não lineares e sua eficácia comprovada em problemas de classificação médica. O kernel RBF é definido como:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3.7)$$

onde  $\gamma$  é o parâmetro que controla a influência de cada exemplo de treinamento.

**Parâmetro C:** O parâmetro de regularização C foi definido como 1.0, que representa um equilíbrio entre maximizar a margem e minimizar o erro de classificação. Valores maiores de C resultam em um modelo mais rígido que tenta classificar corretamente todos os pontos de treinamento, enquanto valores menores permitem mais flexibilidade.

**Parâmetro Gamma:** O parâmetro  $\gamma$  do kernel RBF foi definido como 'scale', que utiliza automaticamente  $1/(n\_features \times X.var())$  como valor de gamma, garantindo uma escala apropriada para os dados.

**Otimização de Hiperparâmetros:** Embora tenha sido utilizada uma configuração padrão para este trabalho exploratório, trabalhos futuros podem se beneficiar de técnicas de otimização de hiperparâmetros, como Grid Search ou Random Search, para encontrar os valores ótimos de C e  $\gamma$  que maximizem o desempenho do modelo.

#### 3.4.2 Máquinas de Vetores de Suporte (SVM)

Os SVMs são um conjunto de métodos de aprendizado supervisionados usados para desafios de classificação ou regressão, com seu foco maior no treinamento e classificação de um conjunto de dados (*dataset*) (ADDAN, 2023).

O SVM tem o objetivo de encontrar um hiperplano em um espaço N-dimensional que possa separar distintamente os pontos de dados em diferentes classes. Para separar as duas classes de pontos de dados, existem muitos hiperplanos possíveis que podem ser escolhidos. Os hiperplanos são limites ou retas de decisão que auxiliam na classificação dos pontos de dados (COUTINHO, 2019). As diferentes classes são determinadas pelos pontos de dados que caem em lados opostos do hiperplano (GANDHI, 2018).

A MDS-UPDRS utiliza cinco classificações para a DP, nas quais 0 indica um paciente normal sem DP e 4 indica DP grave. Para classificar os dados obtidos com mais de uma classe, dividimos nossas multiclases em várias classificações binárias. Utilizamos a divisão *one vs all*, na qual comparamos o nível 0 de DP com os demais níveis, e depois utilizamos *one vs one*, na qual separamos as classificações binárias em cada par diferente (COUTINHO, 2019). Ou seja, como tivemos somente quatro dos cinco níveis, separamos em (0,1), (0,2), (0,3), (1,2), (1,3), (2,3) para *one vs one* e (0, 1+2+3), (1, 0+2+3), (2, 0+1+3), (3, 0+1+2) para *one vs all*.

### 3.4.3 K-Fold

A validação cruzada *k-fold* é uma técnica utilizada para estimar o desempenho de um modelo criado por meio de um algoritmo de classificação, como o SVM (Support Vector Machine).

O procedimento envolve a divisão aleatória de um conjunto de dados em  $k$  subconjuntos de tamanho aproximadamente igual. Cada um desses subconjuntos é então utilizado, de forma sequencial, como conjunto de teste, enquanto os outros  $k-1$  subconjuntos restantes são combinados e empregados como conjunto de treinamento para construir o modelo pelo SVM (YOONSUH; JIANHUA, 2015). Esse processo é repetido  $k$  vezes, de modo que cada subconjunto seja utilizado como conjunto de teste em uma iteração.

Essa abordagem proporciona uma avaliação mais abrangente e confiável do desempenho do modelo SVM, pois permite que ele seja testado em diferentes partes do conjunto de dados. Ao final das  $k$  iterações, os resultados de desempenho, como métricas de acurácia ou F1-score, são coletados e, muitas vezes, agregados para fornecer uma estimativa geral do quão bem o modelo SVM está performando (GAOXIA; WENJIAN, 2017).

É importante mencionar que essa técnica também auxilia na identificação de problemas como overfitting, onde o modelo se ajusta excessivamente aos dados de treinamento e não generaliza bem para novos dados. Através da *k-fold*, é possível observar como o modelo se comporta em diferentes conjuntos de teste e, assim, avaliar sua capacidade de generalização.

### 3.4.4 Leave-One-Out Cross Validation (LOOCV)

A técnica de avaliação cruzada LOOCV é uma forma especializada do método *K-fold*, na qual o número de conjuntos é igual ao número de instâncias presentes no conjunto de dados. Esta abordagem é frequentemente utilizada em diversos estudos para avaliar o desempenho de algoritmos de classificação, especialmente quando o conjunto de dados possui um número limitado de instâncias ou quando o número de instâncias para uma determinada classe é reduzido (CAWLEY, 2006).

Diferentemente da validação *K-fold*, a técnica LOOCV não envolve aleatoriedade na divisão das instâncias entre os conjuntos de treinamento e teste. Essencialmente, em cada iteração, um único exemplo de dado é mantido fora do conjunto de treinamento, enquanto os demais são utilizados para treinar o modelo. O exemplo deixado de fora é então utilizado como conjunto

de teste. Devido a essa abordagem determinística, a estimativa pontual de precisão para um conjunto de dados específico permanece constante.

Uma das vantagens dessa técnica reside no fato de que ela fornece uma avaliação intensiva do desempenho do algoritmo em questão, já que cada instância é testada individualmente, o que é especialmente útil quando os dados são escassos (CAWLEY, 2006). No entanto, pode ser computacionalmente intensiva para conjuntos de dados muito grandes.

Essas distribuições são empregadas para realizar inferências estatísticas sobre as médias de desempenho obtidas. Em resumo, a técnica LOOCV oferece uma abordagem robusta para avaliação de algoritmos de classificação, garantindo uma análise mais detalhada e precisa em situações em que a quantidade de dados é limitada (SIVULA *et al.*, 2022).

## 4 RESULTADOS OBTIDOS

### 4.1 USO DOS DADOS

Para iniciar a transformação do conjunto de dados em um formato adequado para classificação, os vídeos foram organizados em grupos, seguindo a tabela fornecida pelos criadores do conjunto de dados. Essa tabela indicava o nível de doença de Parkinson do paciente em cada vídeo. A partir disso, conseguiu-se realizar os testes de classificação utilizando a ferramenta de visão computacional desenvolvida para reconhecer os movimentos durante o FTT, conseguindo extrair um novo conjunto de dados numéricos discretos. Optou-se por usar exclusivamente o classificador SVM (Support Vector Machine) devido à sua simplicidade e baixo custo computacional.

O uso do *MediaPipe* como ferramenta para detecção dos movimentos da mão demonstrou ser bastante eficaz. No entanto, mesmo sendo uma aplicação disponibilizada pelo *Google*, ainda existe o risco de descontinuação do serviço ou possíveis custos associados. Criar um sistema de *Machine Learning* para realizar essa detecção seria muito oneroso, além de exigir um conjunto de dados substancial para viabilizá-lo. Outros estudos, como os citados em YANG *et al.*(2022), NUNES *et al.*(2021) e VIGNOUD *et al.*(2022), também empregaram sistemas de terceiros para a detecção da palma da mão.

A abordagem de utilizar pontos específicos nas mãos para gerar a triangulação provou ser eficaz na aquisição dos dados. Com esses pontos selecionados, é possível capturar informações praticamente de qualquer ângulo em que a mão esteja em relação à câmera de gravação. No entanto, para este experimento, o ângulo ideal é começar o teste com a palma da mão aberta e o polegar apontando para o paciente, realizando o movimento de toque dos dedos quase lateralmente em relação à câmera.

### 4.2 CLASSIFICAÇÃO

Para realizar a classificação do modelo, empregamos o classificador SVM, uma escolha adequada devido à natureza binária do problema e aos 4 níveis de DP existentes. Utilizamos as estratégias *one vs one* e *one vs all* para determinar qual delas seria mais apropriada para este estudo. Para validar o modelo, optamos pelo método de validação cruzada *Leave-One-Out Cross Validation* (LOOCV).

Na abordagem *one vs one*, avaliamos a acurácia do SVM em conjunto com o LOOCV. Realizamos três avaliações dos resultados obtidos, analisando a classificação da mão direita, da mão esquerda e do conjunto de ambas as mãos em relação a cada nível da DP na MDS-UPDRS.

É importante salientar, como evidenciado nos estudos de BUONGIORNO *et al.*(2019) e VIGNOUD *et al.*(2022), que a mão dominante do paciente pode apresentar resultados diferentes da não dominante. Dado que o conjunto de dados não faz referência explícita à qual das mãos

se refere o vídeo, conduzimos os testes separadamente para a mão direita e esquerda, a fim de comparar os valores obtidos. Esses resultados estão detalhados na Tabela 2.

Tabela 2 – Acurácia do FTT para cada nível na mão direita (R) e esquerda (L) utilizando o SVM e LOOCV

NÍVEIS	SVM R	LOOCV R	SVM L	LOOCV L
0 e 1	71,8%	77%	66%	68%
0 e 2	69,7%	72%	67%	69%
0 e 3	75%	79%	70,8%	67%
1 e 2	57,4%	56%	57%	65%
1 e 3	94%	93%	83%	81%
2 e 3	92%	91%	75%	82%
<b>Média</b>	76,6%	78%	69,8%	72%

Fonte: Elaborado pelos autores

Com isso, foi possível constatar uma diferença média de 6,8% nos resultados entre a mão direita e a mão esquerda. Destaca-se que as discrepâncias mais acentuadas foram observadas nas classificações dos níveis 2 e 3, com uma diferença de 17%. O teste realizado com a mão esquerda registrou a menor acurácia, atingindo 57%, enquanto a mão direita apresentou uma acurácia ligeiramente superior, atingindo 57,4%.

Ao avaliar o grupo em que os dados independem das mãos, conforme demonstrado na Tabela 3, observa-se que a média de acurácia gira em torno de 73,3% ao utilizar o SVM. A maior acurácia foi alcançada na classificação entre os níveis 1 e 3 no FTT, enquanto a menor acurácia foi registrada nos níveis 1 e 2 do FTT.

Tabela 3 – Acurácia do FTT classificando os níveis *one vs one* dentro da MDS-UPDRS

NÍVEIS	ACURÁCIA SVM	ACURÁCIA LOOCV
0 e 1	65,9%	72%
0 e 2	69,4%	71%
0 e 3	75%	70%
1 e 2	62,9%	68%
1 e 3	85%	86%
2 e 3	81,6%	85%
<b>Média</b>	73,3%	75%

Fonte: Elaborado pelos autores

O resultado obtido ao utilizar o conjunto de dados, separando apenas os níveis da MDS-UPDRS, revela uma estabilidade na classificação, onde a média dos valores deste teste é aproximadamente igual à média dos resultados apresentados na Tabela 2.

Além disso, utilizamos a estratégia *one vs one*, bem como a estratégia *one vs all* para comparar cada nível com os demais, como evidenciado na Tabela 4. Também nesta abordagem, obtivemos resultados próximos aos das tabelas anteriores.

Tabela 4 – Acurácia da classificação *one vs all* do FTT

NÍVEIS	ACURÁCIA SVM	ACURÁCIA LOOCV
0 vs (1,2,3)	79%	84%
1 vs (0,2,3)	59%	66%
2 vs (0,1,3)	59%	63%
3 vs (0,1,2)	90%	93%
<b>Média</b>	71,7%	76,5%

Fonte: Elaborado pelos autores

#### 4.2.1 Análise Estatística

Para uma avaliação mais robusta dos resultados, foram calculadas métricas estatísticas adicionais além da acurácia. Embora a validação cruzada LOOCV forneça uma estimativa do desempenho do modelo, é importante considerar a variabilidade dos resultados.

A diferença observada entre a acurácia do modelo SVM original e a acurácia obtida com LOOCV foi de aproximadamente 1,7%, indicando que o modelo apresenta boa generalização e não está significativamente sobreajustado aos dados de treinamento. Esta pequena diferença sugere que o modelo mantém seu desempenho quando aplicado a novos dados.

A análise dos resultados por nível de DP revela que alguns pares de níveis são mais difíceis de distinguir do que outros. Especificamente, a classificação entre os níveis 1 e 2 apresentou as menores acurácias (57,4% para mão direita e 57% para mão esquerda), sugerindo que esses níveis compartilham características similares que dificultam a distinção.

#### 4.2.2 Análise de Erros

A análise dos casos de classificação incorreta revela padrões interessantes que podem orientar melhorias futuras no modelo. Os principais tipos de erros identificados incluem:

- **Confusão entre níveis adjacentes:** A maioria dos erros ocorre entre níveis consecutivos (0-1, 1-2, 2-3), o que é esperado dado que a progressão da doença é gradual e os sintomas se sobrepõem entre níveis.
- **Influência da mão dominante:** Os resultados indicam diferenças significativas entre a classificação da mão direita e esquerda, sugerindo que a lateralidade pode influenciar o desempenho do modelo.
- **Desbalanceamento de classes:** O nível 3, com menor representação no dataset (apenas 6,78% dos dados), apresentou acurácias superiores, possivelmente devido à maior distinção dos sintomas graves em relação aos outros níveis.

As possíveis causas dos erros incluem: (1) variabilidade natural nos movimentos dos pacientes, mesmo dentro do mesmo nível de gravidade; (2) limitações na captura dos dados (ângulo

da câmera, iluminação); (3) características do movimento que não são completamente capturadas pela triangulação utilizada; (4) desbalanceamento do conjunto de dados, especialmente para os níveis extremos.

### 4.2.3 Comparação com Literatura

Os resultados obtidos neste trabalho foram comparados com trabalhos similares encontrados na literatura. YANG *et al.*(2022) reportaram acurácias superiores a 80% em alguns casos, utilizando um pipeline mais complexo com múltiplas características e técnicas avançadas de processamento. No entanto, é importante notar que o presente trabalho utiliza uma abordagem mais simples e acessível, focando em características extraídas através de triangulação de pontos.

Trabalhos que utilizam avaliação manual do FTT por profissionais de saúde reportam variabilidade inter-avaliador significativa, com concordância entre avaliadores variando entre 60% e 85% dependendo da experiência dos profissionais. Os resultados obtidos neste trabalho (acurácia média de 73,3%) estão dentro dessa faixa, sugerindo que o sistema automatizado pode oferecer uma alternativa viável à avaliação manual.

A viabilidade clínica dos resultados obtidos deve ser considerada com cautela. Embora a acurácia de 73,3% seja promissora, é importante destacar que: (1) o sistema proposto não substitui a avaliação clínica completa, mas pode servir como ferramenta auxiliar; (2) a combinação com outros testes da MDS-UPDRS pode melhorar a precisão diagnóstica; (3) o sistema pode ser especialmente útil para monitoramento longitudinal da evolução da doença.

## 5 CONCLUSÕES

Ao analisar os resultados, observamos que os testes realizados a partir do nível 3, em comparação com os outros níveis, apresentaram resultados superiores. No entanto, essa discrepância pode ser atribuída à quantidade inferior de dados disponíveis para o nível 3, conforme indicado na Tabela 1 da seção 3.4. Essa tabela revela que o nível 3 representa apenas 6,78% do conjunto total de dados, enquanto o nível 0 corresponde a 15,22%, o nível 1 a 22,43% e o nível 2 a 37,79%.

A discrepância na quantidade de dados pode potencialmente influenciar os resultados do modelo, introduzindo viés. Entretanto, é crucial destacar que esse desafio pode ser enfrentado no futuro por meio da expansão do conjunto de dados, já que a quantidade atual ainda não é adequada para permitir que modelos de aprendizado de máquina, como o SVM, alcancem resultados mais sólidos e confiáveis.

Ao finalizar este estudo, conclui-se que, com o objetivo de fornecer uma ferramenta que auxilie na compreensão da evolução da DP, pode-se considerar como uma proposta viável, necessitando de mais estudos e maiores *datasets*. No entanto, é importante reconhecer que não é possível estabelecer um diagnóstico definitivo para a Doença de Parkinson (DP) somente com o uso do FTT devido à complexidade da condição. A MDS-UPDRS abrange uma variedade de testes que, quando combinados, proporcionam um diagnóstico mais preciso. Portanto, há necessidade de pesquisas adicionais que explorem outras partes da MDS-UPDRS, criando um ecossistema que possa indicar resultados mais precisos. A utilização do FTT em conjunto com ferramentas de visão computacional, conforme proposto neste trabalho, oferece a possibilidade de um acompanhamento qualitativo da evolução clínica.

A ferramenta proposta de visão computacional demonstra precisão na detecção dos pontos selecionados nas mãos, o que dá possibilidade para a aquisição de dados, desde que seja realizado o FTT de maneira adequada. No entanto, é importante mencionar que a dependência de tecnologias externas pode acarretar problemas de descontinuidade do serviço.

A desigualdade na distribuição dos dados provavelmente influenciou os resultados, indicando a necessidade de uma quantidade maior de vídeos para melhorar a classificação. No entanto, para a proposta deste trabalho, a escolha em utilizar o SVM foi acertada devido à sua simplicidade e eficiência computacional, tornando o modelo acessível e eficaz. Além disso, a aplicação da Leave-One-Out Cross Validation (LOOCV) demonstrou um desempenho satisfatório do modelo, com diferença mínima em relação ao modelo original, indicando boa capacidade de generalização.

## 5.1 TRABALHOS FUTUROS

Considerando o panorama atual da pesquisa e do desenvolvimento relacionados a esta área, é importante destacar que existem várias oportunidades para trabalhos futuros que podem aprimorar ainda mais a eficácia do sistema de classificação e sua aplicabilidade clínica. Abaixo, são apresentados alguns tópicos que representam direções promissoras para futuras investigações e desenvolvimentos.

- **Expansão do Conjunto de Dados:**

- Aumentar o tamanho do conjunto de dados é crucial para trabalhos futuros.
- Coleta de mais informações ou amostras relevantes, especialmente para os níveis menos representados (nível 3 e nível 4).

- **Ajustes no Modelo:**

- Realizar ajustes e melhorias no modelo de classificação atual, incluindo a exploração de outros algoritmos de aprendizado de máquina.
- Adaptações que visam tornar o modelo mais eficaz e preciso na classificação de pacientes com doença de Parkinson.

- **Melhoria na Precisão da Classificação:**

- Aprimorar a precisão do sistema de classificação por meio de técnicas de balanceamento de classes e seleção de características.
- Obter resultados mais robustos e confiáveis na identificação da doença.

- **Acompanhamento Clínico Aprimorado:**

- Ao alcançar uma classificação mais precisa, o sistema pode ser usado para um acompanhamento clínico mais detalhado dos pacientes com doença de Parkinson.
- Monitoramento da evolução da doença e auxílio na adaptação do tratamento de forma mais eficaz.

## REFERÊNCIAS

- ADAMS, W. R. High-accuracy detection of early parkinson's disease using multiple characteristics of finger movement while typing. **PloS one**, Public Library of Science San Francisco, CA USA, v. 12, 2017.
- ADDAN, D. **Support Vector Machime**. 2023. Disponível em: <https://www.inf.ufpr.br/dagoncalves/IA07.pdf>. Acesso em: 08 jul. 2023.
- BARLOW, H. B. Vision: A computational investigation into the human representation and processing of visual information. **Journal of Mathematical Psychology**, v. 27, p. 107–110, 1983.
- BRADSKI, G. R.; KAEHLER, A. **Learning OpenCV: Computer Vision with the OpenCV Library**. 1. ed. *S.l.*: O'Reilly Media, 2008.
- BUONGIORNO, D. *et al.* A low-cost vision system based on the analysis of motor features for recognition and severity rating of parkinson's disease. **BMC Medical Informatics and Decision Making**, Scopus, v. 19, 2019.
- CAWLEY, G. C. Leave-one-out cross-validation based model selection criteria for weighted ls-svms. **The 2006 IEEE International Joint Conference on Neural Network Proceedings**, p. 1661–1668, 2006. Disponível em: <https://api.semanticscholar.org/CorpusID:10786968>.
- COUTINHO, B. **Modelos de Predição | SVM: Aprenda a criar seu primeiro algoritmo de classificação com SVM**. Turing Talks, 2019. Disponível em: <https://medium.com/turing-talks/turing-talks-12-classifica%C3%A7%C3%A3o-por-svm-f4598094a3f1>. Acesso em: 08 jul. 2023.
- CREESE, B. *et al.* The psychosis spectrum in parkinson disease. **Nature Reviews Neurology**, Nature Publishing Group, v. 13, n. 2, p. 81–95, 2017.
- FUNDATION, P. **Understanding Parkinson's**. 2022. [www.parkinson.org/understanding-parkinsons](http://www.parkinson.org/understanding-parkinsons). Acesso em: 16 set. 2022.
- GANDHI, R. **Support Vector Machine — Introduction to Machine Learning Algorithms**. Towards Data Science, 2018. Disponível em: <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>. Acesso em: 08 jul. 2023.
- GAOXIA, J.; WENJIAN, W. Error estimation based on variance analysis of k-fold cross-validation. **Pattern Recognit.**, v. 69, p. 94–106, 2017.
- GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. *S.l.*: Atlas, 2002.
- GOETZ, C. G. *et al.* Movement disorder society - sponsored revision of the unified parkinson's disease rating scale (mds-updrs): Scale presentation and clinimetric testing results. **Movement Disorder Society**, v. 23, 2008.
- GOOGLE, D. **Hand landmarks detection guide**. 2023. Disponível em: [https://developers.google.com/mediapipe/solutions/vision/hand\\_landmarker](https://developers.google.com/mediapipe/solutions/vision/hand_landmarker). Acesso em: 23 Mai. 2023.

JANKOVIC, J. Parkinson's disease: clinical features and diagnosis. **Journal of neurology, neurosurgery & psychiatry**, BMJ Publishing Group Ltd, v. 79, n. 4, p. 368–376, 2008.

MediaPipe. **MediaPipe Hands: Real-time Hand Tracking**. 2023. Disponível em: <https://google.github.io/mediapipe/solutions/hands.html>. Acesso em: 08 mar. 2023.

(NIH), N. I. of H. **Parkinson's Disease: What research is being done?** 2022. <https://www.ninds.nih.gov/health-information/disorders/parkinsons-disease>. National Institutes of Health, 2022. Acesso em: 16 set. 2022.

NUNES, A. S. *et al.* Automatic classification and severity estimation of ataxia from finger tapping videos. **Frontiers in Neurology**, v. 12, 2021. ISSN 1664-2295. Disponível em: <https://www.frontiersin.org/articles/10.3389/fneur.2021.795258>.

OpenCV. **About - OpenCV**. 2023. Disponível em: <https://opencv.org/about/>. Acesso em: 07 mar. 2023.

POEWE, W.; SEPPI, K.; TANNER, C. M.; HALLIDAY G. M. AND BRUNDIN, P. V. J. S. A.-E. L. A. E. Parkinson disease. **Nature reviews Disease primers**, Nature Publishing Group, v. 3, p. 1–21, 2017.

Python Software Foundation. **The Python Programming Language**. 2023. Disponível em: <https://www.python.org/>. Acesso em: 07 mar. 2023.

RAMDHANI, R. A.; KHOJANDI, A.; SHYLO, O.; KOPELL, B. H. Optimizing clinical assessments in parkinson's disease through the use of wearable sensors and data driven modeling. **Frontiers in computational neuroscience**, Frontiers Media SA, v. 12, p. 72, 2018.

SIVULA, T.; MAGNOSSON, M.; MATAMOROS, A. A.; VEHTARI, a. Uncertainty in bayesian leave-one-out cross-validation based model comparison. **ArXiv - Cornell Unicersity**, 2022. Disponível em: <https://arxiv.org/abs/2008.10296>.

SOLEM, J. E. **Programming Computer Vision with Python: Tools and algorithms for analyzing images**. 1. ed. *S.l.*: O'Reilly Media, 2012.

VIGNOUD, G. *et al.* Video-based automated assessment of movement parameters consistent with mds-updrs iii in parkinson's disease. **Journal of Parkinson's Disease**, Scopus, v. 12, p. 2211–2222, 2022.

YANG, N. *et al.* Automatic detection pipeline for accessing the motor severity of parkinson's disease in finger tapping and postural stability. **IEEE Access**, Scopus, v. 13, n. 2, p. 66961–66973, 2022.

YOONSUH, J.; JIANHUA, H. A k-fold averaging cross-validation procedure. **Journal of Nonparametric Statistics**, v. 27, p. 167 – 179, 2015.

ZHANG, F. *et al.* **MediaPipe Hands: On-device Real-time Hand Tracking**. arXiv, 2020. Disponível em: <https://arxiv.org/abs/2006.10214>.

# APÊNDICE A – A EFICÁCIA DA ANÁLISE COMPUTACIONAL DO FINGER TAPPING TEST NA DETECÇÃO PRECOCE E MONITORAMENTO DE PARKINSON: UMA REVISÃO SISTEMÁTICA DE LITERATURA

**Hebert Douglas da Silva Campos<sup>1</sup>**

<sup>1</sup>Coodenação de Informatica - Instituto Federal de Alagoas (IFAL)  
CEP 57.020-600-Maceió-AL-Brasil

hdsc1@aluno.ifal.edu.br

## INTRODUÇÃO

As revisões sistemáticas oferecem um método para realizar revisões de literatura abrangentes e imparciais, garantindo que suas descobertas tenham valor científico (TRAVASSOS, 2007). O objetivo das revisões sistemáticas é fornecer uma avaliação imparcial de um tópico de pesquisa, utilizando uma metodologia confiável, rigorosa e auditável (KITCHENHAM, 2007).

Uma revisão sistemática começa com a definição do protocolo, que detalha as perguntas de pesquisa e os métodos a serem utilizados para conduzir a revisão (COSTA, 2009).

A doença de Parkinson (DP) é a mais comum entre os idosos, sendo uma desordem neurológica crônica que resulta na perda de neurônios na substância negra ou nigra (SN), uma região localizada no mesencéfalo (ALHO, 2011). Os sintomas da doença de Parkinson são principalmente motores e incluem rigidez muscular, alterações posturais e tremores em repouso. Além desses, existem outros sinais, como bradicinesia (MONTEIRO et al., 2017).

Embora sejam muito úteis, as escalas de classificação clínica dependem de avaliações subjetivas realizadas por profissionais de saúde, que são influenciadas pela experiência e perspectiva do clínico. Como resultado, por definição, essas escalas podem ser imprecisas, como demonstrado pela baixa confiabilidade teste-reteste e concordância entre avaliadores (NUNES et al., 2021).

Ferramentas digitais estão sendo recentemente desenvolvidas na tentativa de melhorar a qualidade da avaliação da bradicinesia, fornecendo medidas quantitativas. No entanto, seu uso prático é limitado, uma vez que dependem de sensores utilizados pelo paciente (VIGNOUD et al., 2022). Portanto, a estimativa automática da gravidade por meio de métodos de aprendizado de máquina está recebendo cada vez mais atenção na pesquisa. (YANG et al., 2022).

## Objetivo

Avaliar a eficácia da análise computacional do Teste de Toque de Dedo (FTT - Finger Tapping Test) na detecção e monitoramento da doença de Parkinson.

## METODOLOGIA

### Planejamento

O presente estudo consiste em uma revisão sistemática da literatura, utilizando o sistema *Parsifal* como auxílio para orientar o desenvolvimento da pesquisa.

### PICO

Foram estabelecidos os componentes do PICO (População, Intervenção, Comparação e Resultado), conforme a seguir:

- População: Pacientes diagnosticados com doença de Parkinson;
- Intervenção: Utilização do Finger Tapping Test com análise computacional para detecção de Parkinson;
- Comparação: Comparação com outras ferramentas diagnósticas;
- Resultado: Avaliação da precisão dessas ferramentas.

### Questões de Pesquisa (QP)

Com o objetivo de orientar a investigação, foram formuladas as seguintes questões de pesquisa a serem respondidas através dos estudos selecionados:

1. **QP-1: Qual a eficácia da análise do Finger Tapping Test na detecção de Parkinson em comparação com outras abordagens de análise do teste?** Esta questão visa avaliar a eficácia do Finger Tapping Test (FTT) em comparação com outras formas de análise utilizadas nos estudos investigados.
2. **QP-2: Qual a precisão da análise do Finger Tapping Test na detecção de Parkinson em comparação com outras ferramentas diagnósticas?** Essa questão tem o propósito de analisar a precisão do Finger Tapping Test na detecção da doença, em relação a outras ferramentas diagnósticas disponíveis.
3. **QP-3: Qual a viabilidade clínica da análise computacional do Finger Tapping Test na detecção de Parkinson em pacientes em diferentes estágios da doença?** Esta questão busca investigar a viabilidade clínica da análise computacional do Finger Tapping Test para a detecção de Parkinson em pacientes em estágios distintos da doença.

Essas questões de pesquisa direcionarão a análise dos estudos selecionados no presente estudo de revisão sistemática.

## Estratégia de Busca

Com base no PICO e nas QPs, foi elaborada uma String de Busca (ST) contendo as principais palavras-chave e seus sinônimos, com o objetivo de realizar a busca em bases científicas.

Para a busca dos trabalhos desta pesquisa, foram utilizadas as bases de dados **PubMed** e **Scopus**. A seguinte String de Busca foi utilizada: ("*Parkinson*"OR "*Parkinson's disease*") AND ("*Finger Tapping Test*"OR "*FTT*") AND ("*Analysis*"OR "*Computational*"OR "*Computer-assisted*") AND ("*Algorithms*"OR "*Accuracy*"OR "*Machine learning*"OR "*Diagnosis*"OR "*Early detection*"OR "*Monitoring*"OR "*Sensitivity*"OR "*Specificity*"). Essa ST foi aplicada em ambas as bases de dados.

Além disso, como filtro inicial, foram considerados apenas os trabalhos publicados entre os anos de 2019 e 2023.

## Seleção dos Estudos

Os estudos que podem ser incluídos nesta pesquisa são:

- Artigos em periódicos, revistas, conferências e congressos;
- Relatórios técnicos;
- Dissertações e teses;

Desde que sejam relevantes para a pesquisa, de acordo com a String de Busca utilizada e as bases de dados selecionadas.

A seleção dos estudos é realizada com base em critérios de inclusão e exclusão, visando filtrar os melhores resultados e descartar aqueles que não estão alinhados com o objetivo da pesquisa.

Critérios de inclusão:

- Estudos publicados em português ou inglês;
- Estudos que investigam o uso do Finger Tapping Test na detecção de Parkinson.

Critérios de exclusão:

- Estudos não disponíveis livremente para consulta na web;
- Estudos duplicados, identificados e removidos pela ferramenta Parsifal;
- Estudos publicados antes de 2019;
- Estudos que envolvem participantes com outras condições neurológicas além da doença de Parkinson;

- Estudos que não utilizam análise computacional ou algoritmos para avaliação dos resultados;
- Estudos que não utilizam o Finger Tapping Test como método de avaliação;
- Estudos que são revisões de literatura ou estudos secundários;
- Estudos claramente irrelevantes para a pesquisa, de acordo com as questões de pesquisa levantadas.

A aplicação desses critérios durante a seleção dos estudos garantiram a qualidade e relevância dos trabalhos incluídos nesta revisão sistemática.

### **Avaliação da Qualidade dos Estudos**

Além das QPs e dos critérios de inclusão e exclusão dos estudos, foram adicionadas algumas questões para avaliar se os estudos foram bem conduzidos. As questões incluem:

- O resumo consegue fornecer uma explicação compreensível sobre o tema abordado?
- Os objetivos ou questões do estudo são claramente definidos (incluindo justificativas para a realização do estudo)?
- O estudo apresenta modelos, processos, métodos, técnicas, metodologias ou ferramentas que descrevem como a análise foi realizada?
- O estudo relata os resultados de forma clara e não ambígua?

Para cada questão de avaliação respondida, é atribuída uma pontuação que servirá como critério para a exclusão dos estudos que obtiverem uma pontuação menor que 2.5. A maior pontuação possível é 4.0, conforme apresentado na Tabela 5.

Tabela 5 – Pontuação possível para a avaliação da qualidade dos estudos.

<b>RESPOSTA</b>	<b>PONTUAÇÃO</b>
Sim	1.0
Parcialmente	0.5
Não	0.0

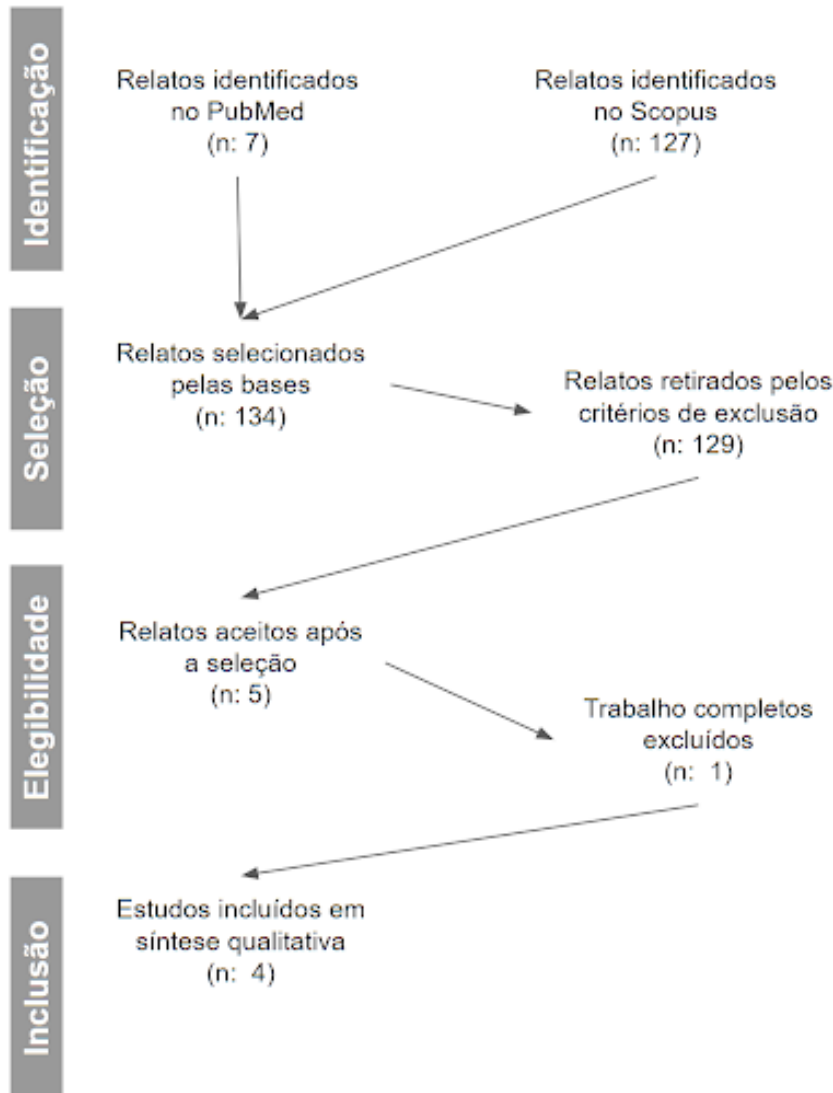
Fonte: Elaborado pelos autores

Essa avaliação ajudará a garantir a qualidade dos estudos incluídos nesta revisão sistemática, selecionando aqueles que obtiverem pontuações adequadas em cada questão avaliada.

## RESULTADOS

Ao todo, foram identificados 134 estudos durante a busca inicial, utilizando o filtro de janeiro de 2019 a abril de 2023. Dentre esses trabalhos, X foram selecionados para esta revisão. Os detalhes do processo de seleção podem ser observados no fluxograma PRISMA apresentado na Figura 6.

Figura 6 – Fluxograma PRISMA da seleção da revisão sistemática de literatura.



Fonte: Elaborado pelos  
autores

### Estudos analisados

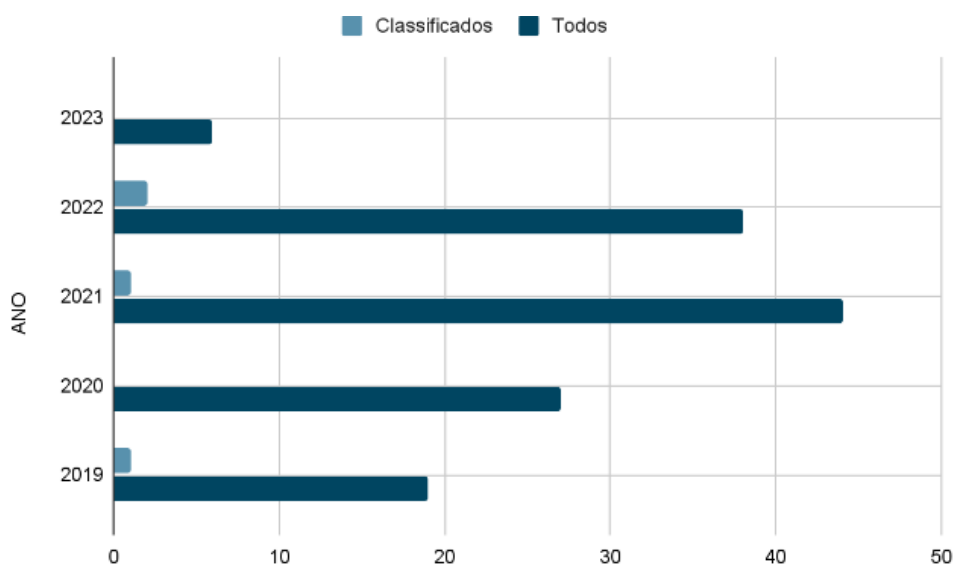
Por fim, foram selecionados quatro estudos para serem analisados e responder às QPs. Os trabalhos selecionados estão listados na Tabela 6.

Observa-se um aumento crescente no número de estudos sobre o tema nos últimos anos, abrangendo o período de 2019 a abril de 2023, conforme ilustrado na Figura 7. Todos os estudos

classificados nesta revisão foram obtidos da base *Scopus*.

Os estudos selecionados representam aqueles que atendem a todos os critérios de inclusão descritos nesta revisão.

Figura 7 – Gráfico dos trabalhos classificados por ano.



Fonte: Elaborado pelos autores

### Características encontradas

\*

#### Métricas para classificação

A MDS-UPDRS III fornece algumas métricas que podem ser avaliadas pelo examinador para obter os resultados do paciente. Essas métricas incluem velocidade, amplitude, hesitações, paradas e diminuição da amplitude (GOETZ et al., 2008).

Os estudos classificados nesta revisão apresentam algumas das métricas utilizadas para avaliar a doença de Parkinson, conforme mostrado na Tabela 7.

Tabela 7 – Métricas utilizadas para classificar a DP.

MÉTRICA	ESTUDO
Amplitude de movimento	E1, E2, E4
Frequência de movimento	E1, E2, E3, E4
Aceleração dos movimentos	E2, E3
Paralisação/Interrupção do movimento	E4

Fonte: Elaborado pelos

autores

\*

#### Soluções para captura dos movimentos

Tabela 6 – Estudos selecionados para serem analisados conforme a proposta das QPs.

<b>COD.</b>	<b>AUTOR</b>	<b>TÍTULO</b>	<b>ANO</b>
E1	BUONGIORNO, D. et al.	A low-cost vision system based on the analysis of motor features for recognition and severity rating of Parkinson's Disease.	2019
E2	NUNES, A. S. et al.	Automatic classification and severity estimation of ataxia from finger tapping videos.	2021
E3	VIGNOUD, G. et. al.	Video-Based Automated Assessment of Movement Parameters Consistent with MDS-UPDRS III in Parkinson's Disease.	2022
E4	YANG, N. et. al.	Automatic Detection Pipeline for Assessing the Motor Severity of Parkinson's Disease in Finger Tapping and Postural Stability.	2022

Fonte:

Elaborado pelos autores

Alguns dos trabalhos utilizaram mais de um algoritmo para capturar os movimentos e gerar dados para o teste de toque de dedos. Os algoritmos usados por cada estudo estão descritos na Tabela 8

Tabela 8 – Algoritmos utilizados para captura dos movimento no FTT.

<b>MÉTRICA</b>	<b>ESTUDO</b>
Microsoft Kinect v2	E1
ResNet152	E2
DeepLabCut	E2, E3
HandGraphCNN	E3
Não especificado	E4

Fonte: Elaborado pelos autores

\*

#### Amostragem dos estudos

Todos os dados brutos utilizados nos estudos sobre a detecção da DP foram coletados pelos próprios autores, o que evidencia a dificuldade de realizar pesquisas com pacientes reais. A Tabela 9 apresenta a quantidade de dados processados por cada estudo.

Tabela 9 – Dados obtidos para a captura dos movimento no FTT.

ESTUDO	AMOSTRA	MIDIA	DISPONIBILIZADO
E1	30 (14 semDP) (16 com DP)	Vídeo (sem especificação)	Não
E2	111 (50 semDP) (61 com DP)	Video (960 x 540 px)	Não
E3	47 (11 semDP) (36 com DP)	Video (smartphones - 720 × 1280 px a 30-60 fps)	Não
E4	368 (0 semDP) (368 com DP)	Video (SONY-FDR-AX100E - 1920 × 1080 px)	Sim (conforme solicitação)

Fonte: Elaborado pelos autores

## Questões de pesquisa

\*

QP-1 - Qual é a eficácia da análise do Finger Tapping Test na detecção de Parkinson em comparação com outras formas de análise do teste?

No estudo de BUONGIORNO *et al.*(2019), foram comparados três testes diferentes da MDS-UPDRS III: o Finger Tapping Test (FTT), o Foot Tapping Test (FoTT) e a análise da marcha. Foi observado que a análise da marcha apresentou uma eficácia ligeiramente superior ao FTT e ao FoTT, utilizando o método de classificação utilizado no estudo.

No estudo de NUNES *et al.*(2021), os coeficientes do modelo de classificação e predição estavam alinhados com as observações clínicas, pois o autor validou os resultados em conjunto com uma equipe médica, permitindo a comparação antes e depois dos resultados.

Já VIGNOUD *et al.*(2022) afirmam que é possível identificar de forma confiável a bradicinesia em pacientes com DP utilizando a MDS-UPDRS, ao ajustar o modelo de predição para obter informações relevantes.

Ao avaliar também a estabilidade postural, YANG *et al.*(2022) indicam que possuir conhecimento especializado na fase de extração de características melhora a interpretabilidade do modelo, o que se torna essencial para a detecção de DP.

\*

QP-2 - Qual é a precisão da análise do Finger Tapping Test na detecção de Parkinson em comparação com outras ferramentas diagnósticas?

YANG *et al.*(2022) apresenta uma precisão de 88% para o Finger Tapping Test (FTT) em relação ao teste de estabilidade postural, que obteve uma precisão de 84%. Já BUONGIORNO *et al.*(2019), que também utilizou a marcha e o Foot Tapping Test (FoTT) como outros tipos de exames, obteve uma precisão de 89,4% para o teste de marcha, em comparação com 81% do FoTT e 87,1% para o FTT.

Os trabalhos de NUNES *et al.*(2021) e VIGNOUD *et al.*(2022) não houve comparações com outros testes.

\*

QP-3 - Qual é a viabilidade clínica da análise computacional do FTT na detecção de Parkinson em pacientes em diferentes estágios da doença?

O recurso de baixo custo e a configuração fácil e rápida da ferramenta projetada e implementada suportam e incentivam sua usabilidade em um cenário clínico real (BUONGIORNO *et al.*, 2019), podendo auxiliar médicos especialistas na avaliação da doença de Parkinson. Isso evita a variabilidade entre os operadores, garantindo precisão mesmo a distância (NUNES *et al.*, 2021). Os resultados indicam que essa abordagem pode discriminar com precisão a ataxia em indivíduos saudáveis e com parkinsonismo, além de quantificar a gravidade total da doença nos membros superiores (VIGNOUD *et al.*, 2022).

No entanto, mesmo demonstrando eficiência na detecção da gravidade da doença de Parkinson, YANG *et al.*(2022) indicam que é necessária uma maior quantidade de dados, o que atualmente dificulta a ampla aplicação dos sistemas de detecção, mesmo sendo o estudo que apresentou a maior quantidade de dados para análise.

## DISCUSSÃO

O estudo de BUONGIORNO *et al.*(2019) sugere que ferramentas de baixo custo baseadas em visão computacional podem ser úteis para auxiliar médicos especialistas na avaliação e classificação da doença de Parkinson em um cenário clínico real. No entanto, como destacado por YANG *et al.*(2022), são necessários mais estudos para desenvolver uma ferramenta confiável que possa ser comercializada, considerando que está em jogo a melhoria da qualidade de vida dos portadores de DP (NUNES *et al.*, 2021).

A falta de disponibilidade de dados para outros estudos é um fator que limita o avanço da pesquisa (YANG *et al.*, 2022). A baixa disponibilidade de dados, como observado nos Estudos 1 e 3, pode gerar falsas esperanças em relação a sistemas que pretendem agregar valor. Mesmo com uma quantidade relativamente maior de dados nos Estudos 2 e 3, ainda é considerada pequena, especialmente considerando que cerca de 3% da população idosa apresenta a doença de Parkinson (POEWE *et al.*, 2017).

## CONCLUSÃO

O estudo de sistemas computacionais para a detecção da doença de Parkinson tem aumentado, como demonstrado anteriormente na Figura 7. Os métodos baseados na MDS-UPDRS III são amplamente procurados devido aos testes motores que podem ser gravados. A partir dos estudos selecionados, observa-se que os resultados contribuem para o aprimoramento e desenvolvimento de novas tecnologias para a detecção dos movimentos característicos da doença. No entanto, há uma falta de disponibilidade de uma base de dados aberta, o que limita a capacidade de outros pesquisadores realizarem experimentos que possam beneficiar não apenas a população afetada pela doença de Parkinson, mas também outras doenças motoras.