


UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA



DANIEL HILÁRIO DA SILVA

**AVALIAÇÃO QUANTITATIVA DA RIGIDEZ DE PUNHO EM PESSOAS COM A
DOENÇA DE PARKINSON POR MEIO DE UMA ÓRTESE ATIVA**

UBERLÂNDIA
2025

DANIEL HILÁRIO DA SILVA

**AVALIAÇÃO QUANTITATIVA DA RIGIDEZ DE PUNHO EM PESSOAS COM A
DOENÇA DE PARKINSON POR MEIO DE UMA ÓRTESE ATIVA**

Tese de **Doutorado** apresentada ao **Programa de Pós-graduação em Engenharia Biomédica** da Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, como requisito parcial para obtenção do título Doutor em Ciências.

Área de concentração: Engenharia Clínica, Desenvolvimento e Avaliação de Tecnologias em Saúde.

Orientador: Prof.º Dr. Adriano Alves Pereira
Coorientadora: Prof.^a Dr.^a Selma Terezinha Milagre

UBERLÂNDIA
2025

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

S586 Silva, Daniel Hilário da, 1981-
2025 AVALIAÇÃO QUANTITATIVA DA RIGIDEZ DE PUNHO EM PESSOAS
COM A DOENÇA DE PARKINSON POR MEIO DE UMA ÓRTESE ATIVA
[recurso eletrônico] / Daniel Hilário da Silva. - 2025.

Orientador: Adriano Alves Pereira.

Coorientadora: Selma Terezinha Milagre.

Tese (Doutorado) - Universidade Federal de Uberlândia,
Doutorado em Engenharia Biomédica.

Modo de acesso: Internet.

DOI <http://doi.org/10.14393/ufu.te.2025.633>

Inclui bibliografia.

1. Engenharia biomédica. I. Pereira, Adriano Alves, 1964-,
(Orient.). II. Milagre, Selma Terezinha, 1962-, (Coorient.). III.
Universidade Federal de Uberlândia. Doutorado em Engenharia
Biomédica. IV. Título.

CDU: 62:61

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
Coordenação do Programa de Pós-Graduação em Engenharia
Biomédica

Av. João Naves de Ávila, 2121, Bloco 3N, Sala 115 - Bairro Santa Mônica, Uberlândia-MG,
CEP 38400-902

Telefone: (34) 3239-4761 - www.ppgeb.feelt.ufu.br - ppegb@feelt.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Biomédica				
Defesa de:	Tese; 012, PPGEB				
Data:	vinte e quatro de outubro de dois mil e vinte e cinco	Hora de início:	08:00h	Hora de encerramento:	10:50h
Matrícula do Discente:	12013EBI002				
Nome do Discente:	Daniel Hilário da Silva				
Título do Trabalho:	AVALIAÇÃO QUANTITATIVA DA RIGIDEZ DE PUNHO EM PESSOAS COM A DOENÇA DE PARKINSON POR MEIO DE UMA ÓRTESE ATIVA				
Área de concentração:	Engenharia Biomédica				
Linha de pesquisa:	Engenharia Clínica, Desenvolvimento e Avaliação de Tecnologias em Saúde				
Projeto de Pesquisa de vinculação:	Caracterização da rigidez em pessoas com a doença de Parkinson por meio de uma órtese de punho				

Reuniu-se via Videoconferência pelo GoogleMeet (<http://meet.google.com/vam-xkfr-omt>), a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Biomédica, assim composta: Professores Doutores: Carlos Dias Maciel - UNESP; Maria Fernanda Soares de Almeida - IFTM; Iraides Moraes Oliveira - UniRV; Gabriella Lelis Silva - UFU; Selma Terezinha Milagre - PPGEB/UFU coorientadora do candidato.

Iniciando os trabalhos a presidente da mesa, Dra. Selma Terezinha Milagre, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir a senhora presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Selma Terezinha Milagre, Professor(a) do Magistério Superior**, em 24/10/2025, às 10:52, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Maria Fernanda Soares de Almeida, Usuário Externo**, em 24/10/2025, às 10:52, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **GABRIELLA LELIS SILVA, Professor(a) Substituto(a) do Magistério Superior**, em 24/10/2025, às 10:52, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Carlos Dias Maciel, Usuário Externo**, em 24/10/2025, às 10:58, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Iraides Moraes Oliveira, Usuário Externo**, em 29/10/2025, às 15:47, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6786389** e o código CRC **F99AAA80**.

Dedico a Deus, que me carregou nos dias difíceis e celebrou comigo cada conquista, sendo sempre meu guia e inspiração. Aos meus pais, Valdivina e Wiliam, que sempre me ensinaram com amor o valor da fé, do trabalho e do esforço. Às minhas irmãs, Mônica e Simone, por estarem sempre ao meu lado.

À minha querida esposa, Cristiane (Cris), companheira de todas as horas, e aos meus filhos, Laís e Miguel, que com amor, paciência e alegria suportaram minhas ausências e meu humor nem sempre fácil, sendo a minha maior motivação para continuar.

Dedico também aos voluntários que aceitaram participar da pesquisa, em especial às pessoas com a Doença de Parkinson, cuja coragem e determinação são uma verdadeira inspiração de vida.

Não poderia deixar de dedicar este trabalho também à memória das mais de 700 mil vidas perdidas para a COVID-19 no Brasil, doença que marcou profundamente minha trajetória e reforçou em mim a fé, a importância da ciência e o valor do apoio da minha família.

Por fim, deixo uma homenagem eterna aos meus avós: Divina Lenza da Silva (*in memoriam*), que com simplicidade e sabedoria acreditava que um dia teríamos um doutor na família e sempre me incentivou a buscar o conhecimento; e ao meu avô Petronílio Hilário Simões (*in memoriam*), que conviveu por mais de uma década com a Doença de Parkinson, mas nunca deixou de estar presente, com carinho e dedicação, mesmo nos momentos em que a doença lhe tirava as forças. A eles, toda a minha gratidão e amor.

AGRADECIMENTOS

Agradeço, com todo o carinho, à minha família, que foi meu porto seguro em cada etapa desta jornada.

Aos meus pais, Valdivina e Wiliam, pelo amor incondicional, pelos ensinamentos de vida e pelo apoio constante que sempre me deram. Às minhas irmãs, Mônica e Simone, pela amizade e pelo companheirismo de irmãos que se transformam em amigos para a vida inteira. Aos meus sobrinhos Bruno, Renato e Mariany, que, com alegria e entusiasmo, sempre trouxeram leveza aos meus dias.

Sou grato também aos meus cunhados, Renato Brasileiro e Fabiano Corrêa Barbosa, e à minha sogra, Maria Neuzadete, pela presença e pelo generoso apoio em tantos momentos importantes. Estendo ainda minha gratidão aos meus parentes mais próximos, que, de diferentes maneiras, me incentivaram e estiveram ao meu lado. Cito aqui, de forma representativa, meus primos Lucas, Thiago, Diogo, Jaqueline e Luciana, que simbolizam esse afeto familiar ampliado que sempre me fortaleceu.

À minha esposa, Cristiane, minha eterna companheira de vida e de sonhos, agradeço por seu amor incondicional, por sua paciência infinita e por sua compreensão generosa em cada passo desta caminhada. Esta trajetória foi muito mais do que acadêmica: foi marcada por momentos desafiadores, agravados pela pandemia de COVID-19, pelas idas e vindas aos hospitais e pelo enfrentamento da Acalásia, uma doença autoimune que exigiu ainda mais força de todos nós. Em meio a tudo isso, Cris esteve sempre ao meu lado, firme e presente, junto com nossos filhos Laís e Miguel, sendo meu alicerce e a razão pela qual nunca deixei de acreditar que seria possível chegar até aqui.

Ao meu orientador, Prof. Dr. Adriano Alves Pereira, agradeço pela orientação atenta e pelo acompanhamento próximo ao longo de todo o desenvolvimento desta tese. À minha coorientadora, Profa. Dra. Selma Terezinha Milagre, agradeço pelo apoio constante, pelas contribuições precisas e pela disponibilidade em compartilhar conhecimento, elementos que foram essenciais para a construção e finalização deste trabalho.

Ao Instituto Federal Goiano (IF Goiano), instituição da qual tenho orgulho de fazer parte no Campus Cristalina, deixo meu agradecimento pelas políticas institucionais de capacitação que tornam possível a qualificação de seus servidores, reafirmando o compromisso com a excelência do ensino público e o desenvolvimento científico e tecnológico do país. Não poderia deixar de reconhecer o apoio de colegas e gestores que estiveram ao meu lado nesta caminhada: Eduardo Vasconcelos Silva (Diretor-Geral), Maria de Fátima Lucimara Santos Nóbrega

(Gestora de RH), Cassio Jardim Tavares (Diretor de Pesquisa) e Alécio Rodrigues Nunes (Professor/Pesquisador), que contribuíram com orientação, suporte e incentivo em momentos decisivos desta trajetória.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), agradeço o apoio financeiro, por meio da concessão de uma bolsa, que viabilizou a realização desta pesquisa. Ao Programa de Pós-Graduação em Engenharia Biomédica (PPGEB) e à Universidade Federal de Uberlândia (UFU), agradeço pela oportunidade de formação e pela infraestrutura oferecida para o desenvolvimento desta tese.

De modo especial, agradeço ao secretário do PPGEB, Edson Montes Mundim Filho, cuja atuação sempre foi marcada por retidão, dedicação e compromisso com o serviço público. Sua postura solícita, educada e humana tornou o processo acadêmico mais leve e eficiente, servindo de exemplo de profissionalismo e de respeito aos estudantes. Reconheço nele não apenas um servidor comprometido, mas também alguém que representa com dignidade o valor da educação pública, gratuita e de qualidade.

Aos colegas e estudantes vinculados aos laboratórios que tive a oportunidade de frequentar nesta jornada, deixo minha sincera gratidão. Embora tenha atuado principalmente no NIATS, também transitei pelo NTA, o que me permitiu vivenciar diversas experiências, colaborações e amizades.

No NIATS, agradeço especialmente a Luanne Mendes, Caio Tonus Ribeiro, Leandro Rodrigues, Eduardo Neto e José Renato Munari Nardo, pela convivência e apoio em tantos momentos. No NTA, sou igualmente grato a Caroline Valentini, Júlia Tannus e Camille Alves, com quem também compartilhei aprendizados e amizades. Estendo esse reconhecimento a todos os demais estudantes de Iniciação Científica e aos colegas que passaram pelos dois laboratórios, cada um deixando sua contribuição para tornar este percurso mais rico e humano.

Em especial, agradeço a Caio Tonus Ribeiro, colega de pesquisa que se tornou um amigo para a vida inteira, pela parceria, pelo companheirismo e pelas incontáveis horas de trabalho e de conversas que tornaram a jornada mais leve. Estendo também meu agradecimento à sua esposa, Mari, pela paciência e compreensão diante das nossas reuniões nos horários mais improváveis.

Estendo ainda meus agradecimentos a todos que fizeram parte da minha trajetória profissional como professor nas redes pública e privada de ensino. Em Goiás, tive a oportunidade de atuar no Colégio Estadual Maria das Dores Campos, no Colégio Estadual Polivalente “Dr. Tharsis Campos” e no Colégio Estadual Dr. David Persicano, na rede estadual;

no Colégio Aprov, da rede privada; e no cursinho Israel Macedo, mantido pela Prefeitura Municipal de Catalão. Posteriormente, tive a honra de lecionar na UFG – Regional Catalão e no CESUC, ampliando minhas experiências no ensino superior. Mais adiante, no IFMG Campus Conselheiro Lafaiete e, por fim, no IF Goiano Campus Cristalina, encontrei novos desafios e amadureci ainda mais como educador. Cada uma dessas instituições, com seus estudantes e colegas de trabalho, contribuiu significativamente para minha formação pessoal e profissional, deixando marcas que levo comigo nesta caminhada.

Por fim, agradeço ao ensino público brasileiro, gratuito e de qualidade, que possibilitou a minha formação acadêmica e o meu desenvolvimento pessoal e profissional. Filho de um mecânico e de uma mãe dedicada ao lar, percorri integralmente a rede pública de ensino, da alfabetização ao doutorado, e é com imenso orgulho que reconheço a relevância dessa trajetória. Trago comigo a gratidão por cada escola, por cada professor e por cada aprendizado que, ao longo do caminho, semearam conhecimento, esperança e transformação. Este trabalho é também fruto dessa história coletiva, que reafirma o valor da educação pública e a importância das políticas públicas implementadas nas últimas décadas, especialmente aquelas relacionadas ao processo de expansão das Universidades Federais e à criação de novos Institutos Federais em todo o país, como instrumentos de mudança social e de ampliação de oportunidades.

Se hoje chego ao doutorado, é porque essa rede de pessoas, instituições e histórias acreditou em mim e me ajudou a acreditar também.

“Para saber o que as pessoas realmente
pensam, preste atenção no que elas fazem, e
não no que dizem.”

René Descartes

RESUMO

Introdução e Revisão Bibliográfica: A rigidez é definida como um aumento da resistência da articulação em movimentos passivos, sendo uma anormalidade do tônus muscular resultante de distúrbios extrapiramidais, com grau de resistência constante independentemente da posição do ângulo da articulação. Embora o tremor seja o sinal motor mais conhecido pela população, as alterações na marcha e a presença de rigidez nos membros superiores e inferiores são as mais incapacitantes para o indivíduo com a doença de Parkinson (DP). A rigidez é um dos sintomas cardinais da DP e é observada em mais de 83% dos indivíduos com a doença. A forma atualmente utilizada pelos profissionais da saúde para a avaliação da rigidez é a Unified Parkinson's Disease Rating System (UPDRS), um método subjetivo, sujeito a erros na avaliação. Este trabalho propôs, desenvolveu e validou um método objetivo para quantificar a rigidez do punho por meio de uma órtese instrumentalizada. O objetivo foi diferenciar indivíduos com DP de controles saudáveis (HC) e correlacionar métricas objetivas com os *scores* clínicos subjetivos. **Metodologia:** Os métodos utilizados para a avaliação objetiva da rigidez, normalmente são compostos por sensores inerciais para registrar o movimento, ou por sensores eletromiográficos que registram a ativação muscular, ou ainda por servomotores, todos esses métodos, geralmente, utilizam os movimentos de flexão e extensão de alguma articulação para o registro dos sinais. No estudo, utilizou-se uma órtese de punho instrumentada (sensores de força e corrente) para aplicar movimentos passivos de flexão e extensão a 30 voluntários: 15 com a DP e 15 do grupo de controle (HC). Doze características biomecânicas foram extraídas dos sinais. Modelos de Aprendizado de Máquina (ML) foram treinados para classificar os grupos (DP vs. HC). Análises estatísticas, incluindo correlação de Spearman e regressão linear múltipla, foram aplicadas para comparar os dados da órtese com o escore de rigidez da MDS-UPDRS. A usabilidade do dispositivo foi avaliada com as escalas: Escala Curta de Fluxo (SFSS) e Escala de Usabilidade do Sistema (SUS). **Resultados:** Os modelos de ML demonstraram alta capacidade de classificação, atingindo 91,30% de acurácia (QDA) com o conjunto completo de características e 86,96% (ET) após seleção de features (CFS). Foi encontrada uma correlação moderada e estatisticamente significativa $\rho = 0,41$ e $p < 0,05$ entre a característica CARGA_Flexao e o escore de rigidez da MDS-UPDRS. O modelo de regressão para a quantificação da rigidez explicou 57,4% (R^2 ajustado) da variabilidade do escore clínico, com base na interação entre variáveis biomecânicas. A usabilidade da órtese foi avaliada como excelente, com escores médios globais de 84,83 na SUS, acima do limiar de 68, e de 4,20 na SFSS, sugerindo um estado de fluxo. **Conclusão:** Os resultados demonstram que a órtese instrumentalizada é uma ferramenta viável, robusta e objetiva para a avaliação da rigidez na DP. A quantificação instrumental apresentou alta acurácia na classificação e associação significativa com a avaliação clínica. Conclui-se que este sistema representa um subsídio técnico promissor para auxiliar no diagnóstico e no monitoramento da DP, reduzindo a subjetividade das avaliações tradicionais.

Palavras-chave: análise quantitativa, aprendizado de máquina, doença de Parkinson; rigidez; órtese; processamento de sinais.

ABSTRACT

Introduction and Literature Review: Rigidity is defined as an increase in joint resistance during passive movements, being an abnormality of muscle tone resulting from extrapyramidal disorders, with a constant degree of resistance regardless of the joint angle position. Although tremor is the most widely known motor signal, gait disturbances and the presence of rigidity in the upper and lower limbs are the most disabling for individuals with Parkinson's Disease (PD). Rigidity is one of the cardinal symptoms of PD and can be found in over 83% of individuals with PD. The method currently used by health professionals to measure rigidity is the Unified Parkinson's Disease Rating System (UPDRS), a subjective method prone to evaluation errors. This thesis proposed, developed, and validated an objective method to quantify wrist rigidity using an instrumented orthosis. The objective was to differentiate individuals with PD from healthy controls (HC) and to correlate objective metrics with subjective clinical scores.

Methodology: Methods used for the objective assessment of rigidity typically consist of inertial sensors to record movement, electromyographic sensors to register muscle activation, or servomotors; all these methods generally use flexion and extension movements of a joint to record signals. In this study, an instrumented wrist orthosis (force and current sensors) was used to apply passive flexion and extension movements to 30 volunteers: 15 with PD and 15 from the control group (HC). Twelve biomechanical features were extracted from the signals. Machine Learning (ML) models were trained to classify the groups (PD vs. HC). Statistical analyses, including Spearman's correlation and multiple linear regression, were used to compare orthosis data with the MDS-UPDRS rigidity score. The device's usability was evaluated using the Short Flow State Scale (SFSS) and the System Usability Scale (SUS).

Results: ML models demonstrated high classification capability, achieving 91.30% accuracy (QDA) with the full feature set and 86.96% (ET) after feature selection (CFS). A moderate and statistically significant correlation $\rho = 0,41$ and $p < 0,05$ was found between the CARGA_Flexao (Flexion Load) feature and the MDS-UPDRS rigidity score. The regression model for rigidity quantification was able to explain 57.4% (Adjusted R^2) of the clinical score variability, based on the interaction between biomechanical variables. The orthosis usability was rated as excellent, with global mean scores of 84.83 on the SUS scale (above the 68 threshold) and 4.20 on the SFSS scale, suggesting a state of flow. **Conclusion:** The results demonstrate that the instrumented orthosis is a viable, robust, and objective tool for assessing rigidity in PD. The instrumental quantification showed high classification accuracy and a significant association with clinical assessment. It is concluded that this system represents a promising technical subsidy to aid in the diagnosis and monitoring of PD, reducing the subjectivity of traditional evaluations.

Keywords: quantitative analysis; machine learning; Parkinson's disease; rigidity; orthosis; signal processing; mathematics modelling.

LISTA DE FIGURAS

Figura 1 – Representação esquemática da substância negra em indivíduos saudáveis e com a doença de Parkinson.	31
Figura 2 – Metodologia de modelagem: transformando um sistema em um modelo	46
Figura 3 – Processo de transformação de dados em informação	47
Figura 4 – Diagrama sobre o AM para os métodos supervisionado e não supervisionado.	51
Figura 5 – Representação da estrutura geral de uma rede neural artificial (ANN).	58
Figura 6 – Representação para a divisão dos dados em subconjuntos para o treinamento e teste dos modelos	61
Figura 7 – Esquema de validação cruzada no método K-fold considerando $k=5$	62
Figura 8 – Identificação das partes que compõem a órtese de punho ativa	71
Figura 9 – Microcontrolador MCLM3006 S RS e atuador LM1247-060-01 no dispositivo projetado para acomodação, impresso em PLA com estrutura adicional para um atuador de menor potência.	72
Figura 10 – Interface do Motion Manager, com um exemplo de dados coletados	73
Figura 11 – Esboço da abordagem utilizada para validação da órtese	77
Figura 12 – Configuração experimental com goniômetro acoplado internamente à órtese para mensuração do ângulo articular do punho	78
Figura 13 – Visão geral do ambiente de coleta de dados	79
Figura 14 – Posicionamento do voluntário com a órtese acoplada ao antebraço dominante	80
Figura 15 – Representação da órtese em movimento automático de extensão (A) e flexão (B) do punho, posicionada nos ângulos máximos de amplitude	82
Figura 16 – Processo de Rastreamento dos Marcadores em Vídeo	85
Figura 17 – Captura e análise dos ângulos articulares do punho utilizando o software Kinovea	86
Figura 18 – Fluxo de trabalho para a modelagem supervisionada com PyCaret.	90
Figura 19 – Fluxograma ilustrando todo o desenvolvimento da pesquisa	94
Figura 20 – Histogramas sobrepostos representando a distribuição das idades dos participantes dos grupos controle e com Doença de Parkinson.	96
Figura 21 – Boxplots das idades dos participantes nos grupos controle e com Doença de Parkinson.	97
Figura 22 – Forest plot dos efeitos padronizados ($z = \Delta/SE$) com intervalos de confiança de 95% para cada variável analisada.	99
Figura 23 – Heat Map mostrando a correlação entre as 12 características antes da aplicação do método de seleção de características.	101
Figura 24 – Comparação da acurácia média (%) antes e depois da otimização para os sete melhores modelos de classificação considerando todas as características	104
Figura 25 – Comparação da acurácia média (%) antes e depois da otimização para os sete melhores modelos de classificação após a aplicação da técnica de CFS.	108

Figura 26 – Comparação da acurácia média (%) dos oito modelos de melhor desempenho, considerando todas as variáveis e após a aplicação da técnica CFS. _____	109
Figura 27 – Matriz de confusão dos três modelos com melhor desempenho no conjunto de teste após aplicação da técnica de CFS. _____	110
Figura 28 – Ranking das dez variáveis de maior importância para: A) ET e B) XGBOOST, após a aplicação da técnica de CFS. _____	111
Figura 29 – Matriz de Confusão para a Classificação dos Scores de Rigidez (MDS-UPDRS item 3.3(a-e) pelo Modelo Preditivo considerando a Acurácia Ampliada com 12 características _____	117
Figura 30 – Matriz de Confusão para a Classificação dos Scores de Rigidez (MDS-UPDRS item 3.3(a-e) pelo Modelo Preditivo Simplificado considerando a Acurácia Ampliada com 3 interações _____	118
Figura 31 – Boxplots com a comparação do escore motor total e da rigidez por sexo para os participantes do grupo com a Doença de Parkinson. _____	121
Figura 32 – Correlação entre idade e escores clínicos. Gráficos de dispersão mostrando a relação entre a idade dos voluntários e (A) o escore motor total e (B) o escore de rigidez. A linha de tendência está representada em ambos os itens. _____	122
Figura 33 – Distribuição dos escores obtidos nas escalas SFSS (A) e SUS (B) nos grupos com DP e HC, representada por meio de gráficos do tipo violin plot, com sobreposição de boxplot e pontos individuais. _____	124

LISTA DE TABELAS

Tabela 1 – Sinais e sintomas da doença de Parkinson _____	33
Tabela 2 – Matriz de confusão para indivíduos saudáveis e com a doença de Parkinson _____	63
Tabela 3 – Distribuição final dos sujeitos válidos para este estudo _____	81
Tabela 4 – Modelo dos dados coletados pelo FAULHABER Motion Manager durante análise dinâmica de movimentação _____	84
Tabela 5 – Dados temporais e angulares obtidos por rastreamento automático dos marcadores durante o movimento de flexão-extensão do punho _____	87
Tabela 6 – Descrição e equação para obtenção das características _____	88
Tabela 7 – Comparação DP vs. HC por variável: teste aplicado, p-valor e IC95% da diferença Δ (DP – HC) _____	99
Tabela 8 – Parâmetros do pipeline para implementação dos modelos para todas as variáveis _____	101
Tabela 9 – Análise de desempenho dos 19 modelos aplicados aos dados de treinamento considerando todas as variáveis _____	102
Tabela 10 – Parâmetros do pipeline para otimização dos modelos usando função tune_model do PyCaret. _____	103
Tabela 11 – Análise de desempenho dos 7 melhores modelos, após o processo de otimização, aplicados aos dados de teste considerando todas as variáveis disponíveis. _____	103
Tabela 12 – Conjunto de variáveis removidas e selecionadas para serem aplicadas aos modelos de ML após o método de seleção de variáveis CFS. _____	105
Tabela 13 – Parâmetros do pipeline para implementação dos modelos para a aplicação de técnica para seleção de características _____	106
Tabela 14 – Análise de desempenho dos 19 modelos ao serem aplicados aos dados de treinamento considerando a técnica de remoção de características. _____	106
Tabela 15 – Análise de desempenho dos 7 melhores modelos aplicados aos dados de teste considerando após a aplicação da técnica de CFS. _____	107
Tabela 16 – Coeficientes de correlação de Spearman (ρ) entre variáveis biomecânicas da órtese e os escores clínicos da UPDRS (Parte III e Item 3.3) _____	113
Tabela 17 – Análise das métricas de desempenho de regressão do modelo final validado _____	114
Tabela 18 – Análise das métricas de desempenho de regressão do modelo otimizado _____	116
Tabela 19 – Resultados descritivos dos escores obtidos por meio da escala MDS-UPDRS. _____	120
Tabela 20 – Resultados descritivos dos escores obtidos nos questionários SFSS e SUS aplicados após a utilização da órtese. _____	123

LISTA DE ABREVIATURAS E SIGLAS

AM	–	<i>Aprendizado de máquina</i>
CFS	–	<i>Correlation Feature Selection</i>
DBS	–	<i>Deep Brain Stimulation</i>
DP	–	<i>Doença de Parkinson</i>
FS	–	<i>Feature Selection</i>
HC	–	<i>Healthy Control</i>
IA	–	<i>Inteligência Artificial</i>
IMU	–	<i>Inertial Measurement Unity</i>
MDS	–	<i>Movement Disorder Society</i>
ML	–	<i>Machine Learning</i>
N	–	<i>Newton</i>
NIATS	–	<i>Núcleo de Inovação e Avaliação Tecnológica em Saúde</i>
OAP	–	<i>Órtese Ativa de Punho</i>
PD	–	<i>Parkinson Disease</i>
RFECV	–	<i>Recursive Feature Elimination with Cross-Validation</i>
RMSE	–	<i>Root Mean Squared Error</i>
TRAP	–	<i>Tremor, Rigidity, Akinesia, Postural Instability</i>
UFU	–	<i>Universidade Federal de Uberlândia</i>
UPDRS	–	<i>Unified Parkinson's Disease Rating Scale</i>
VIF	–	<i>Variance Inflation Factor</i>

SUMÁRIO

1. INTRODUÇÃO	19
1.1 Motivação	19
1.2 Objetivos	22
1.2.1 Objetivos Específicos	22
1.3 Pergunta chave	22
1.4 Hipótese	23
1.5 Metodologia da Pesquisa	23
1.6 Novidades Científicas da Tese	23
1.7 Aplicação dos Resultados Obtidos com a Pesquisa	24
1.8 Informações Relevantes	25
1.9 Divulgação dos Resultados da Pesquisa	26
1.10 Estrutura da Tese	28
2. DOENÇA DE PARKINSON	30
2.1 A Doença de Parkinson	30
2.2 Sinais, sintomas, diagnóstico e tratamento	32
2.2.1 Sinais e Sintomas	32
2.2.2 Diagnóstico	34
2.2.3 Tratamento	35
2.3 Caracterização e Quantificação da Rigidez em Indivíduos com a Doença de Parkinson	36
2.4 Dispositivos para Quantificação da Rigidez	39
3. ESTATÍSTICA, MODELAGEM MATEMÁTICA E APRENDIZADO DE MÁQUINA	42
3.1 Análise Estatística	42
3.2 Modelagem Matemática	45
3.3 Análise de Dados e Processamento de Sinais	47
3.3.1 Análise de Dados	47
3.3.2 Processamento de Sinais	48
3.4 Modelos de Aprendizagem de Máquina	49
3.4.1 Aprendizado Supervisionado	51
3.4.2 Aprendizado Não Supervisionado	52
3.4.3 Modelos de Aprendizado de Máquina para o Caso Supervisionado	53
3.5 Divisão de Dados	60
3.5.1 Divisão em subconjuntos de Treino e Teste	60
3.5.2 Validação Cruzada	62
3.6 Matriz de Confusão	63
3.7 Biblioteca de aprendizado de máquina em Python de código aberto	65
3.7.1 Biblioteca de aprendizado de máquina (PyCaret)	65
3.7.2 Os modelos de classificação do PyCaret	65
3.7.3 As principais funções do PyCaret	66

3.8 Visão Computacional	67
4. MATERIAIS E MÉTODOS	70
4.1 Materiais	70
4.1.1 Arquitetura e organização do <i>hardware</i> personalizado para coleta de dados.	70
4.1.2 Hardware utilizado para avaliação da rigidez	71
4.1.3 <i>Softwares</i> utilizados	73
4.1.4 Validação da órtese	76
4.1.5 Ambiente da coleta de dados	79
4.2 Métodos	80
4.2.1 Caracterização da Amostra	80
4.2.2 Coleta de dados	82
4.2.3 Características de interesse	87
4.2.4 Técnicas para Seleção de Características	89
4.2.5 Apresentação dos dados aos modelos de ML	89
4.2.6 Proposta Metodológica do Modelo Matemático para Predição da Rigidez	91
4.2.7 Avaliação dos voluntários segunda a escala MDS-UPDRS	93
4.2.8 Fluxograma das etapas de coleta, organização e modelagem do trabalho	94
5. RESULTADOS E DISCUSSÃO	96
5.1 Caracterização da Amostra	96
5.2 Resultados da análise estatística para o conjunto de características	98
5.3 Resultado para os modelos de classificação usando ML	100
5.3.1 Resultado dos modelos de ML aplicados a todas as características	101
5.3.2 Resultado dos modelos de ML aplicados ao conjunto de características após a aplicação da técnica de CFS	104
5.4 Avaliação de correlação entre variáveis biomecânicas da órtese e escores clínicos do item III da escala MDS-UPDRS	112
5.5 Resultados para modelo matemático para quantificação da rigidez.	114
5.5.1 Modelo de base com 12 características e modelo simplificado	114
5.5.2 Desempenho do modelo sob a ótica de classificação clínica	116
5.6 Escala MDS-UPDRS e de Avaliação de Usabilidade	119
5.6.1 Escala MDS-UPDRS	119
5.6.2 Avaliação baseada em abordagens centradas na experiência do usuário	122
6. CONCLUSÃO	126
REFERÊNCIAS	128

1. INTRODUÇÃO

1.1 Motivação

A doença de Parkinson (DP) é um distúrbio neurológico que tem como sinais e sintomas clínicos, típicos dessa doença, como a bradicinesia, o tremor, a instabilidade postural e a rigidez muscular (Dickson; Grunevald, 2004).

Entre os distúrbios neurológicos examinados no Estudo Global de Carga de Doenças, Lesões e Fatores de Risco (GBD) de 2015, a doença de Parkinson foi a que mais cresceu em prevalência, incapacidade e mortalidade. Estima-se que o número total de pessoas afetadas pela doença mais do que dobrou globalmente de 1990 a 2015 (Dorsey et al., 2018). Além disso, a DP afeta aproximadamente 10 milhões de pessoas em todo o mundo (Rehman et al., 2019), com o dobro da carga global nos últimos 25 anos, devido ao aumento da longevidade e à maior duração da doença (Dorsey et al., 2018), sendo a segunda doença neurodegenerativa mais comum após o Alzheimer (Naranjo et al., 2016; Rehman et al., 2019). Há consenso de que a prevalência da DP é de cerca de 1 a 2% da população com 65 anos ou mais e de 0,3% da população total (Massano; Bhatia, 2012).

Embora a causa da DP ainda seja desconhecida, vários fatores podem ser considerados como fatores de risco para a DP, incluindo gênero (mulheres têm uma probabilidade ligeiramente maior devido à longevidade), etnia (a DP possui uma maior prevalência na Europa e na América do Norte), genética, exposição a substâncias tóxicas, sequela da encefalite letárgica, traumatismo craniano e estresse emocional (Tanner; Goldman, 1996). O principal fator de risco para a DP é a idade (Bronstein et al., 2009); assim, espera-se que sua prevalência aumente drasticamente nos próximos anos devido ao envelhecimento da população (Dorsey et al., 2018; Massano; Bhatia, 2012).

Segundo Jankovic (2008), os sintomas não motores são comuns e de características pouco apreciadas na DP, como disfunção autonômica, distúrbios neurocomportamentais, distúrbios cognitivos e anormalidades sensoriais e do sono. Ainda segundo o autor, existem quatro características principais da DP que podem ser agrupadas sob a sigla TRAP (*Tremor, Rigidity, Akinesia, Postural Instability*): tremores em repouso, rigidez, acinesia (ou

bradicinesia) e instabilidade postural (Jankovic, 2008), de modo que a rigidez será o foco do trabalho.

Devido aos diferentes perfis e estilos de vida das pessoas com a DP, os sintomas motores e não motores devem ser avaliados no contexto das necessidades e objetivos de cada paciente, ou seja, o diagnóstico é baseado nas características clínicas (Jankovic, 2008). A tomada de decisão em relação ao status de um paciente, sobre um diagnóstico positivo para a doença, ainda se dá de forma clínica, considerando-se a história médica e o exame físico, o que torna a avaliação e classificação do status do indivíduo suscetíveis a erros (Rizzo et al., 2016).

O diagnóstico da DP é conduzido por meio de uma análise clínica, que leva em consideração a presença de pelo menos dois dos quatro sinais e sintomas principais da doença, além do histórico médico e familiar do paciente. Para essa avaliação, utiliza-se como padrão ouro a Escala Unificada de Avaliação da Doença de Parkinson (UPDRS, do inglês *Unified Parkinson's Disease Rating Scale*), otimizada pela *Movement Disorder Society* (MDS), conhecida como MDS-UPDRS (Goetz et al., 2008). Essa escala é uma ferramenta abrangente que auxilia na monitorização do progresso da doença em uma escala de zero, que indica condição normal, a quatro, que indica incapacidade de realizar a tarefa, sendo dividida em quatro partes com itens distintos: avaliação do humor e comportamento (item I), atividades da vida diária (item II), capacidade motora (item III) e complicações motoras (item IV).

Embora o tremor seja o sintoma mais proeminente reconhecido em pacientes com DP, os indicadores que têm o maior impacto na capacidade motora desses indivíduos são as mudanças na marcha e a rigidez. A rigidez é caracterizada como uma resistência, frequentemente acompanhada de tremores, percebida em todo o alcance do movimento passivo de um membro, seja flexão, extensão ou rotação (Jankovic, 2008).

De acordo com Levin *et al.* (2009), a rigidez é definida como uma resistência aumentada durante o movimento passivo de um membro, caracterizada por uma resistência uniforme e constante durante toda a amplitude do movimento (Levin et al., 2009). Essa condição pode manifestar-se em diferentes regiões do corpo, sendo mais comum nos membros superiores, o que dificulta a realização de atividades que envolvam o uso das mãos (Costa; Andrade, 2020). A rigidez está presente em até 89% dos casos e geralmente é avaliada por escalas clínicas, como a UPDRS e a MDS-UPDRS, especialmente na seção motora, que inclui itens para a avaliação da rigidez cervical, dos membros superiores e inferiores (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020).

De maneira subjetiva, a rigidez pode ser examinada por meio do item III da MDS-UPDRS, o qual aborda vários aspectos relacionados aos indivíduos que sofrem com a DP, como

fala, rigidez, destreza dos membros superiores e inferiores, marcha, entre outros. Isso ressalta a importância de uma abordagem que permita uma avaliação objetiva da rigidez em pacientes com DP. Embora diversas metodologias tenham sido propostas ao longo dos anos, a quantificação precisa da rigidez nesses pacientes continua sendo um desafio (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020). A medição objetiva da rigidez pode ser realizada em várias articulações do corpo humano. No entanto, o punho desempenha um papel crucial nas atividades cotidianas, tais como abrir uma porta, atender ao telefone ou alimentar-se, tornando os movimentos de flexão e extensão nessa articulação particularmente relevantes para a qualidade de vida dos indivíduos afetados pela doença (Bruder et al., 2013; Mitsukane et al., 2015). Deste modo, a rigidez presente no punho pode comprometer seriamente a capacidade funcional e a autonomia do indivíduo, impactando diretamente em suas atividades diárias e na sua independência.

Considerando a necessidade de um método de avaliação imparcial que contribua para uma quantificação precisa da rigidez em pacientes com DP, propõe-se a aplicação de uma órtese direcionada ao punho com esse objetivo específico. Essa órtese é composta por um servomotor linear e sensores de corrente e posição integrados, possibilitando a estimativa da força exercida pelo motor por meio de uma constante fornecida pelo fabricante, embora seja necessário calibrar o dispositivo para a finalidade desejada. A partir disso, sinais são adquiridos e processados para analisar a magnitude da força necessária para que a órtese realize os movimentos de flexão e extensão do punho.

Este estudo visa fornecer um suporte significativo para a área da fisioterapia ao propor uma abordagem objetiva para quantificar a rigidez, o que possibilita estabelecer uma classificação mais precisa do estágio da doença. Desta forma, o trabalho visa fornecer uma ferramenta de suporte à avaliação clínica para fisioterapeutas, e não um método de tratamento direto. Ao dispor de um diagnóstico e estadiamento mais acurados, espera-se que os clínicos possam desenvolver estratégias de tratamento e monitoramento mais eficazes e personalizadas. Portanto, a contribuição deste estudo é um subsídio técnico que, ao possibilitar um acompanhamento clínico mais preciso, pode resultar indiretamente na prevenção de possíveis alterações funcionais das mãos e na redução do declínio do desempenho motor e, consequentemente, em uma melhora na qualidade de vida dos indivíduos afetados.

Utilizando uma órtese como ferramenta, este estudo se concentra na classificação de pacientes saudáveis e com DP, com base em características extraídas dos sinais de corrente, deslocamento linear da haste móvel do atuador e deslocamento angular, os quais serão apresentados a modelos de aprendizado de máquina para auxiliar na classificação entre

indivíduos hígidos e com DP. Ao oferecer uma abordagem mais objetiva para o diagnóstico da rigidez em pacientes com DP, este estudo busca preencher uma lacuna na área clínica, potencialmente estabelecendo um padrão normal específico para a variabilidade na execução de determinados movimentos com o uso da órtese de punho em indivíduos saudáveis. Esses resultados complementam as avaliações clínicas tradicionais, auxiliando, assim, no diagnóstico da doença.

1.2 Objetivos

O objetivo geral do estudo é quantificar a rigidez de punho em indivíduos com a DP, analisando os dados de corrente, força e deslocamento angular necessários para que a órtese realize os movimentos de flexão e extensão no punho.

1.2.1 Objetivos Específicos

Os objetivos específicos do estudo são:

- a. Extrair e processar características dos sinais de corrente, força e deslocamento angular obtidos pela órtese;
- b. Identificar variáveis representativas da rigidez em indivíduos com a DP;
- c. Aplicar e validar modelos de classificação para distinção entre indivíduos com e sem DP;
- d. Verificar a correlação entre a rigidez dos indivíduos com a DP e as escalas de avaliação subjetivas, como a UPDRS;
- e. Avaliar a usabilidade da órtese por meio de testes estatísticos e análises de confiabilidade, acrescentando indicadores de aceitabilidade e aplicabilidade clínica.

1.3 Pergunta chave

O uso dos dados, advindos de um microcontrolador presente na órtese para a realização de movimentos de flexão e extensão no punho, associado com ferramentas de visão computacional, poderá ser uma ferramenta para auxílio na compreensão e quantificação da rigidez do punho de indivíduos com a DP e com os diferentes estágios da doença?

1.4 Hipótese

O modelo matemático definido para a previsão da DP poderá ser uma ferramenta que permita a compreensão da rigidez dos indivíduos com a doença e sua relação com os diferentes estágios da doença, possibilitando um melhor entendimento das características da rigidez em indivíduos com DP.

1.5 Metodologia da Pesquisa

A metodologia deste estudo foi estruturada em etapas sequenciais, organizadas de forma a viabilizar uma compreensão aprofundada dos impactos da rigidez em indivíduos com DP. Inicialmente, foi realizada a construção de um banco de dados científicos, contemplando artigos e estudos de referência sobre a DP, com ênfase na rigidez e na voz. Em seguida, procedeu-se a um período de imersão na literatura, reunindo evidências relevantes para embasar as decisões metodológicas e técnicas adotadas ao longo do desenvolvimento do projeto.

Na sequência, buscou-se compreender o funcionamento da órtese ativa de punho desenvolvida, bem como do *software* necessário para sua operação, garantindo a correta parametrização e coleta dos sinais de interesse. Posteriormente, foi realizada a validação da órtese e do protocolo experimental, considerando os resultados obtidos no trabalho de Ribeiro (2023), assegurando a confiabilidade e a precisão das medições realizadas. Por fim, a fase de coleta de dados e modelagem matemática foi conduzida, envolvendo o processamento dos sinais adquiridos, a extração de características relevantes e a aplicação de técnicas de estatística e aprendizado de máquina para análise e interpretação dos resultados.

A metodologia empregada gerou um conjunto robusto de dados biomédicos, cuja coleta será ampliada em novas fases do projeto, fortalecendo a base de informações disponível para análises futuras. Esses dados serão disponibilizados, seguindo diretrizes de boas práticas de compartilhamento científico.

1.6 Novidades Científicas da Tese

Um sistema inovador, como o proposto nesta tese, baseado em sensores, proporcionará as seguintes contribuições:

- a) Caracterização objetiva da rigidez de punho em indivíduos com a DP, por meio de métodos de extração de características e classificação de dados;
- b) Apoiar o especialista em distúrbios do movimento;

- c) Rapidez do processo de coleta de dados;
- d) Quantificação da DP auxiliando o tratamento fisioterapêutico bem como o monitoramento da doença.

Todos esses impactos estão relacionados ao potencial de gerar inovação para apoio a avaliação da rigidez de indivíduos com a DP. Dentre os benefícios, citamos:

- ajudar na compreensão da rigidez de indivíduos com a DP;
- classificação de indivíduos com ou sem a doença de Parkinson com base nos resultados obtidos pela órtese.

Alinhados com o objetivo de contribuir para o avanço das pesquisas relacionadas à DP no Brasil e no mundo, os códigos/*softwares* desenvolvidos com o projeto serão construídos utilizando-se de linguagens e bibliotecas *open source*, amplamente utilizadas na área de aprendizado de máquina e análise estatística e posteriormente disponibilizados. Isso propiciará uma maior velocidade de prototipagem e testes, além da redução dos custos em todo o processo de desenvolvimento.

1.7 Aplicação dos Resultados Obtidos com a Pesquisa

Os resultados obtidos neste estudo oferecem contribuições significativas para o avanço de tecnologias assistivas voltadas ao monitoramento e auxílio no diagnóstico da DP. A descrição detalhada do projeto da órtese ativa de punho, bem como dos protocolos de coleta, processamento de sinais e extração de características, viabiliza a reprodutibilidade do sistema e sua adaptação a diferentes contextos clínicos e de pesquisa. Assim, profissionais da saúde e pacientes podem se beneficiar do uso de tecnologias cada vez mais precisas e eficientes, capazes de proporcionar avaliações objetivas de sinais cardinais, como a rigidez, e apoiar o processo diagnóstico da doença.

Adicionalmente, a aplicação de técnicas de modelagem matemática e aprendizado de máquina para análise da rigidez reforça a perspectiva de auxiliar especialistas na tomada de decisão clínica, auxiliando no diagnóstico da DP de modo a deixá-lo mais seguro, preciso e embasado em evidências quantitativas.

As contribuições deste estudo têm potencial para gerar um impacto duplo, promovendo o avanço científico na área e fornecendo subsídios diretos para a prática clínica, com o objetivo final de melhorar a qualidade de vida dos indivíduos acometidos pela doença.

1.8 Informações Relevantes

O projeto é uma evolução do desenvolvimento e do conhecimento adquirido pelo Núcleo de Inovação e Avaliação Tecnológica em Saúde (NIATS) ao longo dos anos sobre a doença de Parkinson. Essa evolução teve início em 2011, quando a equipe realizou seus primeiros estudos sobre o tremor humano, sem relação com a doença. Nos primeiros estudos foram avaliadas várias formas de obtenção de sinais do tremor, incluindo eletromiografia e sensores inerciais. Nesse período, foi desenvolvida a prótese de punho para controle de tremor, que será utilizada neste projeto. A evolução natural do estudo do tremor, foi a aplicação do conhecimento obtido para a DP.

Assim, várias técnicas de processamento e sensores desenvolvidos e utilizados para o tremor foram também aplicados para a caracterização da DP. A integração dos estudos realizados para o tremor humano e para a DP culminou no projeto desta tese, utilizando a órtese de punho desenvolvida para o estudo do tremor humano, com a inclusão de sensores de força e de corrente, e a necessidade observada pelos pesquisadores do NIATS de uma avaliação objetiva da rigidez de indivíduos com a DP.

A órtese ativa de punho, em seu estado atual, foi adaptada por (Costa; Andrade, 2020), que realizaram adaptações tornou-a mais ergonômica e confortável para uso em indivíduos com rigidez, diminuindo sua massa de 950 para 850 gramas, além de estabelecer um protocolo inicial para a coleta de dados: “a estrutura principal da órtese que é acoplada ao antebraço foi posicionada a 6 cm do processo estilóide da ulna para todos os voluntários. Essa escolha foi baseada em um estudo piloto que sugeriu que essa distância geralmente permitiria a maior amplitude de movimento de flexão e extensão de punho para os voluntários” (Costa; Andrade, 2020).

Contudo, ainda era necessária uma calibração da órtese, conduzida por (Ribeiro, 2023). Dessa forma, estipulou-se que a massa máxima que pode ser movida pelo servomotor utilizado é de 812,64 g, visto que essa é a carga máxima que ele consegue mover de maneira precisa. Além disso, a força exercida pelo motor agora pode ser calculada com maior precisão usando a Equação (9). No intuito de acrescentar maior praticidade e comodidade ao paciente, na análise feita por Ribeiro (2023), propõe-se o uso de ferramentas de visão computacional para obtenção do deslocamento angular durante a execução da atividade.

A pesquisa foi realizada com o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e da Fundação de Amparo à Pesquisa do Estado de Minas Gerais

(FAPEMIG). Adriano Alves Pereira é bolsista do CNPq, Brasil (309525/2021-7); e Daniel Hilário da Silva, bolsista da FAPEMIG. É importante ressaltar que esta pesquisa foi realizada como parte de um projeto colaborativo entre alunos de graduação, mestrado e doutorado. Assim, cada aluno atuou mais ativamente em diferentes etapas, por exemplo: Samila Carolina Costa, à época, aluna de doutorado, concentrou-se na parte ergonômica (Costa; Andrade, 2020); Caio Tonus Ribeiro, à época, aluno de mestrado, realizou a validação da órtese, e Daniel Hilário da Silva, autor desta tese, trabalhou na parte da validação da órtese que resultou no trabalho de (Ribeiro, 2023), atuando de forma mais ativa na coleta de dados, junto com a equipe vinculada ao projeto de pesquisa, no tratamento, na análise e na modelagem, que resultaram neste trabalho.

Esse histórico de pesquisa contínua do NIATS consolida a tese como fruto de um processo científico amadurecido, com forte base multidisciplinar e aplicação clínica relevante.

1.9 Divulgação dos Resultados da Pesquisa

Os resultados da pesquisa foram publicados em quatorze meios de divulgação científica, sendo sete artigos científicos que foram publicados em periódicos revisados por pares, seis em anais de conferências e um capítulo de livro.

Trabalhos publicados em revistas científicas

1. de Lima Gonçalves, V., Ribeiro, C.T., Hilário, D.H., et al. A hybrid linear discriminant analysis and genetic algorithm to create a linear model of aging when performing motor tasks through inertial sensors positioned on the hand and forearm. **BioMedical Engineering OnLine**, Article number: 98, p. 2-27, 2023. <https://doi.org/10.1186/s12938-023-01161-4>.
2. Silva, G. P.; Buso, J. S.; Silva, D. H.; Bernardino Junior, R. Análise tomográfica da espessura óssea vestibular e lingual a partir da inclinação dos implantes odontológicos. *Brazilian Journal of Health Review - BJHR*, <https://ojs.brazilianjournals.>, p. 11691 - 11709, 2023. <https://doi.org/10.34119/bjhrv6n3-261>.
3. Ribeiro, C. T., Pereira, Silva, D. H. da., A. A., Nardo, J. R. M., & Souza, L. R. da S. A Novel Validation Study of a Wrist Orthosis for the Objective Evaluation of Rigidity in Parkinson's Disease. **International Journal of Online and Biomedical Engineering (IJOE)**, Manuscript Number: 50429, p. 90 – 108, 2024. <https://doi.org/10.3991/ijoe.v20i12.50429>.
4. Silva, D. H. da., Ribeiro, C. T., Pereira, A. A., Souza, L. R. da S., et. al. Application of open-source, low-code machine-learning library in Python to diagnose Parkinson's

- disease using voice signal features. **Brazilian Archives of Biology and Technology (BABT)**, vol. 68, p. 1-21, 2025. <https://doi.org/10.1590/1678-4324-2025230860>.
5. Silva, D. H. da., Ribeiro, C. T., Pereira, A. A., Nardo, J. R. M., & Souza, L. R. da S. Exploring essential acoustic features for early Parkinson's disease classification: A machine learning study. **International Journal of Online and Biomedical Engineering (IJOE)**, Manuscript Number: 50503, p. 98 – 120, 2025. <https://doi.org/10.3991/ijoe.v21i02.50503>.
 6. Silva, D. H. da., Ribeiro, C. T., Nardo, J. R. M., Brasileiro, S. H. da S., Souza, L. R. da S, Pereira, A. A. & Andrade, A. de O. A Web Application for exploratory data analysis and classification of Parkinson's Disease patients using machine learning models on different datasets. **Software Impacts**, ISSN 2665-9638, v. 23, p. 1-5, 2025. <https://doi.org/10.1016/j.simpa.2024.100737>.
 7. Souza, L. R. da S, Silva, D. H. da., Ribeiro, C. T., Silva, D. A. da, Nasuto, S. J., Sweeney-Reed, C. M., Pereira, A. A. & Andrade, A. de O. PubMedMetaTool: Automated metadata extraction from PubMed using Python for bibliometric analysis. **Software Impacts**, ISSN 2665-9638, v. 23, p. 1-5, 2025. <https://doi.org/10.1016/j.simpa.2025.100766>.

Capítulo de Livro Publicado

8. Silva, G. P.; Buso, J. S.; Silva, D. H.; Bernardino Junior, R. Análise tomográfica da espessura óssea vestibular e lingual a partir da inclinação dos implantes odontológicos. In: Brazilian Journals. (Org.). Tecnologia e inovação voltados para a odontologia (v.1). 1 ed.: Brazilian Journals Editora, 2024, v. 1, p. 9-29. <https://doi.org/10.35587/brj.ed.0002348>.
9. Sousa, Leandro Rodrigues da Silva; Silva, Daniel Hilário da; Ribeiro, Caio Tonus; Milken, Pedro Henrique Bernardes Caetano; Nasuto, Slawomir J.; Sweeney-Reed, Catherine M.; Andrade, Adriano de Oliveira; Pereira, Adriano Alves. A Bibliometric Study on Parkinson's Disease Based on the Open Access Data of the Michael J. Fox Foundation In: IFMBE Proceedings, ed.1.: **Springer Nature** Switzerland, 2025, v.3, p. 83 - 92. https://doi.org/10.1007/978-3-031-94934-0_9
10. Nardo, José Renato Munari; Ribeiro, Caio Tonus; Alves, Camille Marques; Silva, Daniel Hilário; Neto, Eduardo Moura; Mendes, Luanne Cardoso; Pereira, Adriano Alves; de Oliveira Andrade, Adriano. Patterns in Drawings of Parkinson's Disease Patients Versus Healthy People Utilizing Markerless Object Tracking with Machine Learning In: IFMBE Proceedings, ed.1.: **Springer Nature** Switzerland, 2025, v.3, p. 232 - 242. https://doi.org/10.1007/978-3-031-94934-0_24

Trabalhos completos publicados em anais de congressos

(SEB 2022, 2023 e 2025)

11. Andrade, I. G.; Faria, M. J. N.; Ribeiro, C. T.; Silva, Daniel Hilário; MILAGRE, Selma Terezinha; Pereira, A. A.. Confecção de um Sistema com Sensores Integrados a Laringoscópio. XVI Simpósio de Engenharia Biomédica (**XVI SEB - 2025**), Uberlândia, MG, Brasil. <https://doi.org/10.5281/zenodo.17363825>.
12. Silva, D. H. da., Ribeiro, C. T., Pereira, A. A., Nardo, J. R. M., & Souza, L. R. da S. A low-code machine learning library in Python applied to classify and interpret data of patients with Parkinson's disease using voice records. XV Simpósio de Engenharia Biomédica (**XV SEB - 2023**), Uberlândia, MG, Brasil. <https://doi.org/10.5281/zenodo.10162024>.
13. Nardo, J. R. M., Ribeiro, C. T., Silva, D. H. da., Pereira, A. A., Souza, L. R. da S., & Andrade, A. de O. An experimental protocol for video recording with a smartphone for use in a pre-trained neural network. XV Simpósio de Engenharia Biomédica (**XV SEB - 2023**), Uberlândia, MG, Brasil. <https://doi.org/10.5281/zenodo.10157450>.
14. Silva, D. H. da., Ribeiro, C. T., & Pereira, A. A.. Um estudo sobre o uso de modelos de Machine Learning para o diagnóstico da Doença de Parkinson por meio da análise de voz de pacientes. XIV Simpósio de Engenharia Biomédica (**XIV SEB - 2022**), Uberlândia, MG, Brasil. <https://doi.org/10.5281/zenodo.7490097>.
15. Ribeiro, C. T., Silva, D. H. da., & Pereira, A. A.. Uso de classificadores como ferramenta de auxílio para diagnóstico de incontinência urinária em mulheres: Revisão da Literatura. XIV Simpósio de Engenharia Biomédica (**XIV SEB - 2022**), Uberlândia, MG, Brasil. <https://doi.org/10.5281/zenodo.7492405>.

Essas publicações evidenciam a relevância e aplicabilidade da pesquisa desenvolvida ao longo do período dedicado ao Programa de Pós-graduação em Engenharia Biomédica da UFU.

1.10 Estrutura da Tese

Este trabalho está organizado em seis capítulos. No primeiro, apresenta-se a introdução da pesquisa, contemplando a delimitação do problema investigado, a justificativa para a realização do estudo, os objetivos traçados, os resultados pretendidos, a forma de organização do documento e os meios previstos para a divulgação dos achados ao longo da investigação.

O segundo capítulo dedica-se a uma revisão sobre a Doença de Parkinson, enfatizando a rigidez como um dos sintomas motores cardinais, mas também abordando outros sinais

clínicos recorrentes, os métodos empregados para diagnóstico e avaliação, bem como as principais estratégias terapêuticas atualmente disponíveis.

No terceiro capítulo, são discutidos os fundamentos teóricos que embasam o estudo, abrangendo técnicas estatísticas, métodos de modelagem matemática e abordagens de aprendizado de máquina. Nesse contexto, destaca-se a análise da rigidez, considerada um dos principais sintomas motores da Doença de Parkinson, além da descrição dos métodos utilizados para avaliação, processamento dos dados e desenvolvimento dos modelos preditivos.

O quarto capítulo descreve os materiais, equipamentos e procedimentos metodológicos empregados, com ênfase na coleta e no processamento de dados relacionados à rigidez em indivíduos com a doença, além das estratégias aplicadas para validação dos resultados.

Em seguida, o quinto capítulo apresenta a caracterização da amostra e os resultados obtidos tanto nos modelos de classificação baseados em aprendizado de máquina quanto no modelo matemático proposto para a quantificação da rigidez. São também discutidos os achados relacionados à aplicação da Escala MDS-UPDRS e à avaliação de usabilidade, priorizando abordagens centradas na experiência do usuário.

Por fim, o sexto capítulo reúne as considerações finais, destacando as principais conclusões, as contribuições científicas e práticas alcançadas, as limitações identificadas e as perspectivas para futuras pesquisas na área.

2. DOENÇA DE PARKINSON

Este capítulo tem por objetivo apresentar os fundamentos teóricos essenciais sobre a Doença de Parkinson, fornecendo uma compreensão aprofundada de seus sinais e sintomas, dos métodos de diagnóstico e das abordagens de tratamento. Além disso, o capítulo explora de forma detalhada a caracterização e a quantificação da rigidez em indivíduos com a doença, um dos seus principais sintomas motores, e discute os dispositivos específicos utilizados para essa quantificação.


2.1 A Doença de Parkinson

A doença de Parkinson foi primeiramente observada e documentada por James Parkinson em seu trabalho intitulado *An Essay on the Shaking Palsy*, reconhecendo-a como uma síndrome neurológica (Jankovic, 2008; Parkinson, 2002). Antes desse estudo, alguns sintomas da doença haviam sido descritos de forma isolada em vários textos da literatura, sem que fossem associados a uma síndrome específica (Jankovic, 2008). Diversos pesquisadores contribuíram significativamente para o entendimento da DP, com destaque para os estudos de Charcot, que foi o primeiro a chamar a síndrome em homenagem a James Parkinson (Kempster; Hurwitz; Lees, 2007). Charcot identificou os principais sinais da doença, como tremor, bradicinesia, rigidez e dificuldades de equilíbrio, que continuam sendo fundamentais para diferenciar a DP de outras condições neurológicas, além de ter sido pioneiro em seu tratamento (Massano; Bhatia, 2012).

Estima-se que a DP afeta cerca de 10 milhões de pessoas em todo o mundo, com uma carga global que dobrou entre 1990 e 2015, impulsionada pelo aumento da expectativa de vida e pela maior duração da doença (Dorsey et al., 2018). Após a doença de Alzheimer, a DP é considerada a segunda doença neurodegenerativa mais prevalente (Bronstein et al., 2009; Rehman et al., 2019). Embora a causa da DP ainda não seja completamente compreendida, acredita-se que resulte de uma redução significativa dos neurônios dopaminérgicos localizados nos gânglios da base do cérebro (Tsanas et al., 2011), como ilustrado na Figura 1.

Figura 1 – Representação esquemática da substância negra em indivíduos saudáveis e com a doença de Parkinson.

Área afetada pela doença de Parkinson



Fonte: o autor.

No item (A) tem-se a localização anatômica do mesencéfalo no cérebro humano. Em (B) e (C) tem-se cortes transversais do mesencéfalo que mostram a diferença na integridade da substância negra entre indivíduos com a DP (B) e saudáveis (C), evidenciando a redução da pigmentação característica da região em casos de DP.

O surgimento dos primeiros sinais e sintomas motores está correlacionado com a degeneração dos neurônios na substância negra, uma região localizada na parte ventral do segmento mesencefálico, que é caracterizada por neurônios pigmentados contendo neuromelanina, responsável pela síntese predominante de dopamina como neurotransmissor (Alho, 2011; Dickson; Grünewald, 2004). Esses neurônios desempenham um papel crucial na liberação de dopamina, neurotransmissor essencial para a execução de movimentos coordenados e fluidos (Karapinar Senturk, 2020).

A manifestação dos sinais e sintomas motores da DP surge quando ocorre a perda de 60-80% dessas células produtoras de dopamina, resultando em uma diminuição significativa na produção de dopamina.

A dopamina desempenha um papel essencial nos movimentos involuntários. A diminuição da dopamina pode causar sinais e sintomas motores e não motores na DP (Alho, 2011; Almeida et al., 2019). Devido à deficiência de dopamina no corpo estriado, região cerebral responsável pelo controle dos movimentos, ocorrem os principais sinais motores da doença, sendo elas a bradicinesia, rigidez muscular, tremor e instabilidade postural (Goetz et al., 2008; Jankovic, 2008).

Assim, ressalta-se a importância crucial de identificar características específicas em tarefas motoras, como um meio de diagnosticar precocemente a DP. É fundamental reconhecer sinais distintivos nos estágios iniciais da doença, uma vez que a prevalência da DP é estimada em cerca de 1 a 2% da população com 65 anos ou mais, equivalendo a 0,3% da população total (Massano; Bhatia, 2012). Essa análise precoce pode não apenas possibilitar um tratamento mais eficaz, mas também fornecer subsídios valiosos para prever e gerenciar disfunções relacionadas à DP, contribuindo de forma significativa para uma melhor qualidade de vida das pessoas afetadas pela doença.

2.2 Sinais, sintomas, diagnóstico e tratamento

2.2.1 Sinais e Sintomas

Os sintomas associados à DP podem ser divididos em duas categorias principais: não motores e motores. Os sintomas não motores, embora frequentes, muitas vezes não recebem a devida atenção na avaliação da DP. Estes sintomas englobam disfunções autonômicas, anormalidades cognitivas ou neurocomportamentais, distúrbios do sono e irregularidades sensoriais (Hayes, 2019; Magalhães et al., 2022). Para além dos sintomas mencionados por Jankovic (2008), é importante destacar que a depressão e a ansiedade afetam aproximadamente 35% dos pacientes. Além disso, a perda do olfato é uma manifestação que ocorre em até 90% dos pacientes com DP, podendo surgir anos antes dos sintomas motores, conforme apontado por Hayes (2019).

Segundo Jankovic (2008), a DP apresenta quatro características principais que podem ser agrupadas sob a sigla TRAP (*Tremor, Rigidity, Akinesia, Postural Instability*): tremor em repouso, rigidez, acinesia (ou bradicinesia) e instabilidade postural. Além dessas características, a postura flexionada e os bloqueios motores, congelamento, foram incluídos entre as características clássicas do Parkinsonismo (Jankovic, 2008). Em consonância com o definido por Jankovic, a DP é vista como um distúrbio neurológico que se manifesta por sinais e sintomas clínicos típicos, como bradicinesia, tremor, rigidez muscular (Dickson; Grünewald, 2004) e instabilidade postural (Hayes, 2019).

Parkinsonismo é uma síndrome clínica caracterizada pela presença simultânea de vários problemas motores, como bradicinesia, tremor em repouso, rigidez muscular, perda dos reflexos posturais, postura flexionada e o fenômeno de congelamento. Pelo menos dois desses problemas podem ser observados antes do diagnóstico de Parkinsonismo, incluindo pelo menos

um deles, como tremor em repouso ou bradicinesia (Fahn; Sulzer, 2004). É importante ressaltar que os sinais e sintomas do Parkinsonismo se assemelham aos da DP; no entanto, podem ser atribuídos a causas conhecidas, como drogas ou exposição a neurotoxinas (Tsanas et al., 2011).

Na Tabela 1 é possível observar as características clínicas mais comuns da DP, conforme detalhado por Jankovic (2008), que permitem distinguir entre os sinais e sintomas motores e não motores.

Tabela 1 – Sinais e sintomas da doença de Parkinson

Sinais e sintomas motores	Sinais e sintomas não motores
Tremor, bradicinesia, rigidez, instabilidade postural	Comprometimento cognitivo, bradifrenia, fenômeno da ponta da língua (descoberta de palavras)
Hipomimia, disartria, disfagia, sialorréia	Depressão, apatia, anedonia, fadiga, outros problemas comportamentais e psiquiátricos
Diminuição do balanço dos braços, marcha arrastada, dificuldade de festinação levantando-se da cadeira, virando-se na cama	Sinais e sintomas sensoriais: anosmia, ageusia, dor (ombro, costas), parestesias
Micrografia, corte de alimentos, alimentação, higiene, atividades lentas do cotidiano	Disautonomia (hipotensão ortostática, constipação, disfunção urinária e sexual, sudorese anormal, seborreia), perda de peso
Reflexo glabellar, blefaroespasmos, distonia, deformidade estriatal, escoliose, camptocormia	Distúrbios do sono (distúrbio de comportamento REM, sonhos vívidos, sonolência diurna, fragmentação do sono, síndrome das pernas inquietas)

Fonte: adaptado de Jankovic, 2008

Os sinais e sintomas motores comumente associados à Doença de Parkinson incluem rigidez muscular, bradicinesia, tremores e alterações na marcha (Peres et al., 2021), conforme sintetizado na Tabela 1.

O tremor em repouso destaca-se como o principal sintoma motor, afetando aproximadamente 70% dos pacientes (Peres et al., 2021; Teskey; Elhabiby; El-Sheimy, 2012). Apesar de ser o sintoma motor mais reconhecido, as alterações na marcha e a presença de rigidez nos membros superiores e inferiores são as mais impactantes para o paciente (Prochazka et al., 1997). Esses sintomas podem ter sérias repercussões na vida social e pessoal do paciente,

podendo incluir incapacidade de alimentar-se, beber água, escrever, caminhar e até mesmo falar (Teskey; Elhabiby; El-Sheimy, 2012).

Entre os principais sintomas motores característicos da DP, evidenciando um conjunto de alterações posturais e motoras frequentemente observadas nos indivíduos, estão: postura curvada, rigidez nas costas, cotovelos e punhos flexionados, inclinação do tronco para frente, rosto inexpressivo, redução do balanço dos braços, tremores nas mãos e pernas, quadris e joelhos levemente flexionados, além da marcha arrastada com passos curtos (Alves et al., 2008). Esses sinais são marcadores clínicos relevantes para o diagnóstico e acompanhamento da progressão da doença, e impactam significativamente a mobilidade, independência funcional e qualidade de vida dos indivíduos acometidos.

Apesar do conhecimento dos sinais e sintomas motores e não motores da DP, amplamente estabelecidos por Jankovic (2008) e detalhados na Tabela 1, a UPDRS é considerada inadequada para avaliar a DP em seus estágios iniciais, conforme Peres *et al.* (2021) pois a maioria dos itens está relacionada aos estágios mais avançados da doença. Diante dessa limitação, a literatura oferece diversas propostas que empregam métodos objetivos para o diagnóstico da DP. Entre esses métodos, destaca-se a avaliação do movimento, pois os sintomas e os resultados do tratamento são frequentemente observados através do movimento, incluindo tremor, bradicinesia e discinesia (Peres et al., 2021; Teskey; Elhabiby; El-Sheimy, 2012).

Entretanto, a determinação do status de um paciente, especialmente no que se refere a um diagnóstico positivo para a doença, ainda é predominantemente clínica, com base na história médica e no exame físico, tornando o processo diagnóstico vulnerável a subjetividades e imprecisões clínicas (Rizzo et al., 2016). Como observado por Rizzo et al. (2016), essa abordagem pode resultar em erros na classificação do estado do paciente, evidenciando a importância de melhorias no processo diagnóstico. Além disso, conforme destacado por Karabayir *et al.* (2020), a acurácia do diagnóstico da DP na prática clínica geralmente é de aproximadamente 80%, o que sugere um número significativo de casos não diagnosticados.

2.2.2 Diagnóstico

O diagnóstico da DP continua predominantemente clínico, já que não há um teste definitivo para confirmá-lo durante a vida, exceto em casos raros em que o teste genético pode ser útil. No entanto, do ponto de vista prático, a primeira etapa para diagnosticar a DP é uma anamnese cuidadosa. Isso envolve uma investigação detalhada dos sintomas relatados pelo

paciente e seus familiares, buscando identificar a sequência de eventos e o comprometimento anatômico percebido (Massano; Bhatia, 2012).

A análise do histórico familiar é fundamental, pois pode revelar a presença de distúrbios neurológicos em outros membros da família. Além disso, a investigação da ancestralidade étnica é relevante, já que formas genéticas da DP são mais comuns em certos grupos étnicos, como judeus asquenazes e árabes do norte da África, que têm uma maior incidência de mutações no gene-LRRK2 (Massano; Bhatia, 2012).

Após o diagnóstico da DP, a progressão da doença pode variar consideravelmente. A classificação proposta por Hoehn e Yahr foi desenvolvida com o objetivo de caracterizar o nível de dependência do paciente e representar o grau de dificuldade e incapacidade enfrentados (HOEHN; YAHR, 1967). Essa classificação, que varia do estágio 0 (nenhum sinal da doença) ao estágio 5 (sintomas graves e limitações mais severas), fornece uma estrutura mais clara para avaliar a progressão da DP (Bhidayasiri; Tarsy, 2012). Essa progressão reflete a deterioração gradual do controle motor e a crescente dependência do paciente em relação às atividades diárias, afetando significativamente sua qualidade de vida. Essa escala é similar à UPDRS, conforme mencionado, que auxilia na avaliação do progresso da doença em uma escala de zero, que representa o estado normal, a quatro, que se refere à incapacidade de realizar uma tarefa (Goetz et al., 2008).

2.2.3 Tratamento

Os tratamentos mais comuns para aliviar os sinais e sintomas da DP incluem o uso de fármacos, como levodopa ou medicamentos dopaminérgicos, e procedimentos cirúrgicos, como a estimulação cerebral profunda (DBS, do inglês *Deep Brain Stimulation*) (Cerri; Mus; Blandini, 2019; Jankovic, 2008).

A terapia com levodopa marcou um avanço significativo no tratamento da doença de Parkinson, sendo amplamente adotada pelos pacientes em diferentes estágios da condição. Essa medicação atua como precursora da dopamina, permitindo que os neurônios afetados produzam mais neurotransmissores, resultando no alívio dos sintomas característicos da doença, como tremor, bradicinesia e rigidez. A rigidez, em particular, responde bem à levodopa e é um parâmetro principal monitorado para avaliar a eficácia dos tratamentos farmacológicos (Sepehri et al., 2007). Geralmente, os sintomas iniciais são tratados com levodopa oral e agonistas dopaminérgicos (Fahn; Sulzer, 2004).

Contudo, com o decorrer do tempo, a duração da resposta ao tratamento com levodopa torna-se mais curta e os efeitos colaterais tornam-se mais evidentes. Complicações comuns em

pacientes em tratamento de longo prazo com levodopa oral incluem flutuações na resposta clínica, incluindo discinesia (Gaprielian et al., 2019; Nyholm, 2012). Portanto, a administração contínua da levodopa, que proporcionaria uma estimulação dopaminérgica contínua, é crucial para o gerenciamento das flutuações nos sinais e sintomas motores em pacientes com DP em estágio avançado (Nyholm, 2012).

A estimulação cerebral profunda é outra importante intervenção para a DP. O estudo demonstra que a DBS pode reduzir significativamente a rigidez (Bartels; Harrison; Celicanin, 2024). A cessação da DBS leva a um aumento gradual da rigidez, enquanto a sua retomada resulta em uma melhora quase imediata. Essa resposta é visível em métricas objetivas como a Taxa de Força e a Estimativa de Trabalho. A redução da rigidez promovida pela DBS ocorre de forma mais rápida após o início da estimulação, enquanto o retorno da rigidez após a interrupção do estímulo é mais lento (Perera et al., 2019).

É importante notar que, embora os tratamentos existentes aliviem os sintomas, eles não demonstraram, até o momento, retardar a progressão da patologia subjacente da doença e, por isso, o desenvolvimento de drogas modificadoras da doença é um objetivo crucial. Nesse contexto, a utilização de biomarcadores é encorajada para enriquecer as populações de estudos clínicos, selecionando pacientes com maior probabilidade de progressão e de resposta ao tratamento (Stephenson et al., 2019).

No entanto, devido aos potenciais efeitos adversos dos medicamentos ou à natureza invasiva da cirurgia de DBS, os tratamentos fisioterapêuticos estão ganhando destaque e validação no gerenciamento dos sinais e sintomas da DP, seja como terapia principal ou como tratamento complementar aos medicamentos ou à cirurgia (Wen et al., 2022).

Dessa forma, torna-se evidente que, embora os tratamentos atuais aliviem sintomas, a quantificação precisa de parâmetros como a rigidez é essencial para otimizar o manejo clínico da DP. Tendo apresentado os aspectos clínicos e terapêuticos da doença, passamos agora à discussão sobre os métodos objetivos de quantificação da rigidez.

2.3 Caracterização e Quantificação da Rigidez em Indivíduos com a Doença de Parkinson

A análise da rigidez em indivíduos com DP possui uma trajetória significativa na literatura e tem sido alvo de investigação ao longo dos anos. Em meio a esse contexto, a avaliação da rigidez tem sido objeto de pesquisa contínua, visando aprimorar as técnicas e instrumentos empregados para tal fim (Prochazka et al., 1997). No entanto, Prochazka *et al.* (1997) observaram que a correlação entre essas medições e as avaliações clínicas

correspondentes ainda carece de consenso, o que impacta na falta de uma técnica universalmente aceita.

Embora a rigidez possa não ser o sintoma mais incapacitante na condição em questão, sua avaliação continua sendo um componente crucial para o diagnóstico clínico. Portanto, a disponibilidade de uma abordagem confiável e conveniente para quantificar a rigidez seria de grande importância no contexto da avaliação de tratamentos farmacológicos e técnicas cirúrgicas. A diminuição dos níveis de dopamina nos gânglios da base é fortemente associada à acinesia e rigidez na DP, mas as opiniões sobre os mecanismos fisiopatológicos subjacentes ainda variam, especialmente quanto à contribuição de cada um para a manifestação final dos sinais clínicos (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020).

A rigidez é um sintoma central da DP, presente em mais de 83% dos indivíduos diagnosticados com a condição (Mak; Wong; Hui-Chan, 2007). É tradicionalmente definida como um aumento da resistência ao movimento passivo nas articulações, resultante de disfunções extrapiramidais do tônus muscular. Além disso, caracteriza-se por apresentar um grau de resistência constante, independentemente da posição angular da articulação (Mak; Wong; Hui-Chan, 2007). Existem dois tipos principais de rigidez: a *lead pipe*, que ocorre quando os músculos antagonistas que controlam uma articulação estão recebendo altos níveis de ativação involuntária simultaneamente; e a *cogwheel*, que ocorre quando a rigidez *lead pipe* é acompanhada de tremor (Giuffrida; Rapp, 2016). Apesar dos esforços de pesquisadores, como Levin et al. (2009), a natureza e a origem da rigidez parkinsoniana ainda permanecem obscuras. Vários fatores, como aumento da atividade muscular relacionada ao reflexo de alongamento de longa latência e alterações nas propriedades mecânicas intrínsecas do músculo, são apontados como possíveis contribuintes para a rigidez na DP (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020).

Estudos aprofundados sobre os mecanismos fisiopatológicos da rigidez revelam que ela é influenciada tanto por componentes neurais quanto não neurais (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020; Perera et al., 2019). O componente neural está associado a alterações no sistema nervoso central, como o reflexo de alongamento de longa latência exacerbado, que é uma resposta supraespinal ao alongamento mediada pelo córtex sensório-motor e é virtualmente ausente em indivíduos saudáveis (Bartels; Harrison; Celicanin, 2024; Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020). Outros fatores neurais incluem o aumento do reflexo de alongamento tônico e a reação de encurtamento, uma resposta paradoxal de um músculo que se contrai ao ser encurtado, proeminente em pacientes em estado ‘OFF’, isto é, o período em que a medicação dopaminérgica perde seu efeito e os sintomas motores,

como a rigidez, retornam ou se intensificam. Por outro lado, o componente não neural corresponde às alterações nas propriedades mecânicas viscoelásticas das fibras musculares e dos tecidos conjuntivos passivos. É importante notar que, enquanto o componente neural parece ser modificável por medicação dopaminérgica e estimulação cerebral profunda, o componente não neural não é (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020; Perera et al., 2019).

A avaliação clínica objetiva dos sinais motores da DP, incluindo a rigidez, é baseada em escalas clínicas semiquantitativas, como a MDS-UPDRS, que classifica a rigidez da articulação com pontuação de de 0 a 4 (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020). No entanto, essa avaliação é subjetiva e os examinadores podem cometer erros significativos no diagnóstico (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020; Sepehri et al., 2007). Nos últimos 20 anos, vários pesquisadores têm se empenhado em estabelecer métodos objetivos e quantitativos para avaliação da rigidez na DP, visando complementar os resultados da MDS-UPDRS (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020; Levin et al., 2009; Mak; Wong; Hui-Chan, 2007; Prochazka et al., 1997).

A dependência de escalas ordinais como a MDS-UPDRS (Item 3.3) apresenta desafios significativos, incluindo variabilidade inter e intraavaliador, viés do examinador e baixa sensibilidade devido às demarcações fixas (incapacidade de fornecer classificações fracionárias ou além da escala) (Bartels; Harrison; Celicanin, 2024; Perera et al., 2019; Raiano et al., 2020). Além disso, a avaliação clínica exige a presença física de um avaliador qualificado e não pode ser mitigada por gravação de vídeo, ao contrário de outros sintomas como o tremor. Embora forneçam informações importantes sobre a qualidade de vida, as avaliações clínicas carecem de uma medida contínua e quantificável que possa oferecer maior percepção mecanicista (Perera et al., 2019).

A quantificação objetiva da rigidez é de importância fundamental para avaliar a eficácia terapêutica de intervenções como a medicação dopaminérgica e a estimulação cerebral profunda. Dispositivos como o Dispositivo de Rigidez do Instituto de Biônica (BiRD, do inglês *Bionics Institute Rigidity Device*) demonstraram a capacidade de rastrear mudanças graduais na rigidez ao longo do tempo, como o agravamento progressivo após a cessação da DBS e a melhora rápida após a sua retomada, oferecendo uma visão detalhada das características temporais das flutuações dos sintomas. Essa capacidade de monitoramento contínuo é um avanço significativo, permitindo uma avaliação mais precisa da resposta do paciente aos tratamentos em comparação com as avaliações clínicas pontuais, especialmente em cenários de

ensaios clínicos ou monitoramento domiciliar onde um avaliador qualificado pode estar ausente (Perera et al., 2019).

O impacto da rigidez em pacientes com DP é significativo, afetando negativamente a qualidade de vida e a capacidade de realizar atividades diárias. Portanto, a avaliação precisa desse sintoma é crucial para desenvolver tratamentos eficazes que possam melhorar a funcionalidade dos pacientes. Apesar dos esforços de pesquisa recentes, a avaliação da rigidez ainda representa um desafio (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020).

Neste projeto, é proposto, de forma inédita, a utilização de uma órtese instrumentada, posicionada no punho, composta por um servomotor e sensores de força e de corrente, para avaliação e comparação da rigidez em indivíduos com DP e indivíduos saudáveis, com o objetivo de caracterizar a rigidez dos indivíduos com DP, além de estimar o estágio da doença.

2.4 Dispositivos para Quantificação da Rigidez

No que tange à rigidez muscular, um dos principais sinais motores da DP, caracteriza-se pelo aumento da resistência ao movimento passivo das articulações, causado por disfunções extrapiramidais do tônus muscular. Embora a avaliação clínica tradicional, por meio de escalas como a MDS-UPDRS e a escala de Hoehn & Yahr, seja amplamente adotada, trata-se de um método subjetivo, sujeito à variabilidade e a erros de até 20% no diagnóstico (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020; Sepehri et al., 2007).

De maneira geral, a avaliação clínica da rigidez em indivíduos com a DP é realizada de forma passiva, envolvendo a flexão e a extensão dos membros do paciente (Mak; Wong; Hui-Chan, 2007). Em estudos como o de Mak, Wong e Hui-Chan (2007), a rigidez do tronco em pacientes com DP foi quantificada, revelando maior rigidez nos extensores do tronco em comparação com indivíduos saudáveis, sugerindo uma relação com a postura curvada característica dos pacientes.

Nos últimos anos, têm sido desenvolvidos métodos instrumentais que buscam quantificar a rigidez de forma objetiva, confiável e reprodutível, fundamentais para diagnósticos precisos, avaliação da progressão da doença e monitoramento da resposta terapêutica. Os métodos objetivos para quantificar a rigidez em pacientes com DP podem ser categorizados por sistemas servo-motorizados e robóticos, sensores inerciais e dispositivos vestíveis e métodos fisiológicos e biomecânicos (Perera et al., 2019; Sepehri et al., 2007).

Entre os sistemas servo-motorizados, destacam-se aqueles que realizam movimentos passivos controlados sobre uma articulação, registrando variáveis como torque, força, trabalho

e deslocamento angular. A sensibilidade dessas medições depende da velocidade angular (idealmente entre 140°/s e 190°/s) e da amplitude do movimento (60° a 90°), o que proporciona maior correlação com as escalas clínicas tradicionais (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020).

O exoesqueleto robótico KINARM, que avalia a rigidez por meio de uma tarefa de alongamento passivo, medindo o torque necessário para mover e parar o membro, como o cotovelo, demonstrou ser capaz de diferenciar pacientes com DP de indivíduos saudáveis, quantificar os efeitos da terapia dopaminérgica e apresentar alta acurácia. A ferramenta mostrou-se sensível para quantificar a rigidez em todo o espectro da doença, desde os sintomas mais leves (evitando o efeito de piso) até os mais severos (evitando o efeito de teto), o que a torna aplicável a pacientes em diferentes estágios da doença (Gaprielian et al., 2019).

Já o BiRD, dispositivo vestível posicionado na palma da mão, realiza a flexão automatizada do terceiro dedo e registra forças por meio de transdutores, apresentando correlação moderada com a MDS-UPDRS e capaz de diferenciar estados terapêuticos com ou sem DBS (Perera et al., 2019).

O PDMeter, por sua vez, é um dispositivo vestível no punho que mede a rigidez do punho, capaz de discriminar indivíduos saudáveis de pacientes com DP, e pacientes com DP "OFF" (sem medicação) de pacientes "ON" (com medicação), mostrando uma sensibilidade potencialmente maior do que a escala MDS-UPDRS para a rigidez em extensão. A rigidez em extensão foi consistentemente maior do que a rigidez em flexão (Raiano et al., 2020).

No grupo dos sensores inerciais, são utilizados acelerômetros, giroscópios e magnetômetros para quantificar o movimento de forma portátil e não invasiva. O Personal KinetiGraph (PKG) é um exemplo amplamente citado, sendo capaz de registrar tremores, bradicinesia e discinesia ao longo do dia. Embora não meça diretamente a rigidez, fornece dados complementares importantes para a prática clínica, melhorando a comunicação entre médicos e pacientes (Joshi et al., 2019).

Quanto aos métodos fisiológicos e biomecânicos, destacam-se: a) a eletromiografia de superfície (sEMG), que permite avaliar a atividade muscular durante movimentos passivos, sendo útil para investigar os mecanismos fisiopatológicos associados à rigidez (Tamás et al., 2016); b) a miotonometria, que mede parâmetros como o tônus e a rigidez em N/m com alta reprodutibilidade, embora com correlação clínica ainda limitada; c) a elastografia, técnica baseada em ultrassonografia para mensurar a rigidez de tecidos moles com confiabilidade inter e intraexaminador (ICC > 0,7) (Ferreira-sánchez; Moreno-verdú; Cano-de-la-cuerda, 2020); e d) a miografia acústica (AMG), que avalia diretamente a atividade das fibras musculares por

ondas de pressão, apresentando forte correlação com as escalas clínicas e fácil aplicabilidade (Bartels; Harrison; Celicanin, 2024; Celicanin et al., 2023).

A avaliação da rigidez em pacientes com DP é crucial devido ao seu impacto na qualidade de vida e na capacidade de realizar atividades diárias. Dispositivos mecatrônicos vestíveis, como os apresentados por Raiano *et al.* (2020) e Perera *et al.* (2019), representam avanços significativos nesse campo. Esses dispositivos automatizam o processo de avaliação, permitindo monitoramento contínuo e quantificação precisa da rigidez muscular em diferentes regiões do corpo afetadas pela DP. O trabalho feito por Ribeiro (2023) valida o uso de uma órtese de punho para a quantificação da rigidez de punho em pacientes com DP verificando a capacidade do servomotor utilizado para movimentar até 812,64 g, órtese esta que é tomada como foco desta tese. A partir dessas evidências e da escassez de abordagens focadas especificamente na articulação do punho, esta tese propõe o desenvolvimento e validação de uma órtese inovadora, com potencial para preencher essa lacuna.

Embora diferentes estratégias tenham sido propostas para caracterizar a rigidez na Doença de Parkinson, muitas permanecem restritas a ambientes experimentais ou carecem de validação clínica ampla. A presente tese contribui para esse cenário ao propor uma solução híbrida, que alia instrumentação biomecânica a algoritmos de aprendizado de máquina, superando limitações de métodos tradicionais como a UPDRS. Essa integração amplia o potencial diagnóstico e fornece subsídios objetivos para a prática clínica. Os conceitos apresentados na revisão bibliográfica, especialmente no que se refere às limitações dos métodos clínicos tradicionais de avaliação da rigidez e às possibilidades de dispositivos vestíveis, fundamentaram as escolhas metodológicas adotadas nesta pesquisa. Dessa forma, os próximos capítulos descrevem os procedimentos experimentais, a instrumentação empregada e as estratégias analíticas utilizadas para o desenvolvimento e validação da órtese ativa proposta.

3. ESTATÍSTICA, MODELAGEM MATEMÁTICA E APRENDIZADO DE MÁQUINA

Este capítulo aborda conceitos fundamentais de estatística, de modelagem matemática e de técnicas de aprendizado de máquina que embasam as análises desenvolvidas ao longo desta tese. Descrevem-se os métodos estatísticos empregados para caracterizar e comparar os dados, os princípios de modelagem matemática aplicados às informações coletadas por meio da órtese ativa de punho, bem como as abordagens de aprendizado de máquina utilizadas na etapa de predição e na interpretação dos resultados.

3.1 Análise Estatística

Inicialmente, os dados brutos são explorados por meio de medidas descritivas, como média, mediana, desvio padrão, variância e intervalo interquartil, que permitem caracterizar a tendência central e a dispersão dos dados, bem como identificar valores atípicos que possam influenciar as análises subsequentes (Blair; Taylor, 2013; Espírito-Santo; Daniel, 2015).

Adicionalmente, gráficos exploratórios, como histogramas, *boxplots* e diagramas de dispersão, serão construídos para auxiliar na visualização de padrões e relações entre as variáveis analisadas.

As pesquisas na área médica frequentemente utilizam métodos estatísticos paramétricos para a análise comparativa de dados. Estes testes, no entanto, pressupõem que a variável aleatória segue uma distribuição normal (Espírito-Santo; Daniel, 2015; Le Boedec, 2016). Assim, antes de aplicar os testes adequados, é essencial verificar se os dados seguem uma distribuição normal. Esta verificação é comumente realizada com o teste de Shapiro-Wilk, no qual um resultado não significativo ($p - \text{valor} > 0,05$) indica que a hipótese nula de normalidade não é rejeitada, sugerindo que os dados podem ser analisados por meio de testes paramétricos (Blair; Taylor, 2013; Bruce; Bruce; Gedeck, 2020).

A verificação da normalidade dos dados foi realizada primariamente por meio do teste de Shapiro-Wilk (Le Boedec, 2016; Rosa; Silva, 2020). É importante notar que a eficiência dos testes de normalidade depende do tamanho amostral. Em amostras pequenas (como $n < 30$), o poder estatístico do teste é reduzido, aumentando a probabilidade de um *Erro Tipo II*, ou seja, de falhar em rejeitar a hipótese de normalidade mesmo quando os dados não são normais.

Por esta razão, a decisão de empregar testes paramétricos (Blair; Taylor, 2013; Bruce; Bruce; Gedeck, 2020) ou não paramétricos não se baseará exclusivamente no p-valor do teste de Shapiro-Wilk. Será utilizada uma abordagem combinada, que considera também:

- a) O conhecimento prévio sobre a natureza da variável como as escalas ordinais, a UPDRS, que raramente são de fato normais;
- b) A inspeção visual da distribuição dos dados (por meio de histogramas e gráficos Q-Q).

De modo complementar, quando a normalidade é assumida, recomenda-se verificar a homogeneidade das variâncias entre os grupos por meio do teste de Levene, que avalia se diferentes amostras possuem variâncias estatisticamente semelhantes. Tal passo é fundamental para a seleção do teste t de Student tradicional (com variâncias iguais) ou da sua versão ajustada (teste t de Welch, com variâncias desiguais). Assim, o fluxo lógico para escolha do teste estatístico apropriado se baseia em três etapas principais:

- a) Teste de normalidade (Shapiro-Wilk);
- b) Teste de homogeneidade de variâncias (Levene); e
- c) Seleção do teste de comparação (paramétrico ou não paramétrico), garantindo robustez metodológica à análise dos dados.

Para a comparação da severidade motora entre os sexos, em que a premissa de normalidade possa não ser atendida, deve-se optar pelo teste não paramétrico U de Mann-Whitney. Essa escolha é justificada por sua robustez em amostras de tamanho reduzido, com $n < 30$, e por sua adequação para dados de natureza ordinal ou semiquantitativa com medição imprecisa, que frequentemente violam as suposições de normalidade.

O teste U de Mann-Whitney é uma alternativa apropriada aos testes paramétricos, como o teste t de Student, especialmente quando não há acesso a amostras grandes e normalmente distribuídas ou quando a distribuição dos dados é assimétrica (Nachar, 2008).

O teste opera comparando os postos (*ranks*) das observações entre os grupos, avaliando se as distribuições são diferentes, após a ordenação dos dados em ordem crescente. É importante notar que a hipótese nula (H_0) deste teste é mais geral do que uma simples comparação de medianas. Esta hipótese nula, formalmente, testa se a probabilidade de uma observação aleatória do grupo X ser maior do que a do grupo Y é de 50% ($P(X > Y) = 0.5$). O teste só pode ser interpretado como um teste específico das medianas, sob a suposição restrita de que as distribuições dos grupos têm as mesmas formas e variâncias. Caso essa suposição não seja

atendida, a rejeição da (H_0) indica, de forma mais ampla, que as distribuições diferem estocasticamente. Além disso, ele é menos propenso a resultados falseados na presença de valores extremos em comparação com o teste t, como mencionado por Nachar (2008).

No entanto, é importante notar que, em situações de heterocedasticidade (variâncias distintas entre as populações), o teste U de Mann-Whitney pode amplificar o erro do Tipo I, que se refere à rejeição falsa da hipótese nula (Blair; Taylor, 2013; Bruce; Bruce; Gedeck, 2020; Nachar, 2008). Segundo Nachar (2008), este teste é particularmente apropriado para dados clínicos de escalas, como a MDS-UPDRS, que frequentemente não seguem uma distribuição normal.

Adicionalmente, a fim de investigar uma possível associação entre a idade e a severidade dos sintomas motores, bem como para o cálculo da correlação entre a rigidez e as características biomecânicas da órtese, é recomendado utilizar o teste de correlação de Spearman. A seleção deste teste não-paramétrico é corroborada pela literatura, que o recomenda para avaliar a força e a direção de relações monotônicas, ou seja, quando uma variável tende a aumentar ou diminuir consistentemente em resposta a outra, não necessariamente de forma linear (Mukaka, 2012; Schober; Schwarte, 2018). O coeficiente de Spearman, ao contrário do coeficiente de Pearson, é baseado nos postos (*ranks*) dos dados e é o mais adequado quando os dados não são normalmente distribuídos, são ordinais, ou na presença de valores atípicos, os *outliers* (Mukaka, 2012; Schober; Schwarte, 2018). Embora o coeficiente de Pearson possa ser similar em alguns casos, o Spearman é preferível quando a distribuição dos dados é enviesada ou assimétrica (Mukaka, 2012). Autores como Mukaka (2012) e Schober, Boer & Schwarte (2018) destacam a superioridade do coeficiente de Spearman em cenários com dados não normais, ordinais ou na presença de valores atípicos, fornecendo uma medida de associação mais fidedigna nessas condições. É crucial ressaltar que os coeficientes de correlação descrevem apenas associações e não implicam relações causais.

Para todas as análises, o nível de significância (α) foi fixado em 0,05. Este limiar, embora seja uma decisão arbitrária, é amplamente adotado na pesquisa (Blair; Taylor, 2013; Bruce; Bruce; Gedeck, 2020; Hastie; Tibshirani; Friedman, 2009), indicando que resultados com um *p – valor* inferior a 0,05 são considerados estatisticamente significativos, ou seja, apresentam baixa probabilidade de ocorrer ao acaso, assumindo-se a veracidade da hipótese nula. No entanto, a significância estatística não deve ser confundida com a importância clínica ou prática dos resultados, pois um *p – valor* pequeno pode não garantir que a magnitude do efeito seja grande ou relevante (Espírito-Santo; Daniel, 2015).

Concluídas as análises estatísticas inferenciais, os dados foram preparados para a etapa de modelagem de ML. É fundamental diferenciar as duas abordagens metodológicas: ao contrário dos testes estatísticos clássicos (como o Teste t, que é invariante a transformações lineares, ou o teste U de Mann-Whitney, que usa ranks), os algoritmos de ML, especialmente aqueles baseados em distância, como o SVM são altamente sensíveis às diferentes escalas das características extraídas.

Portanto, como pré-processamento essencial para garantir que todas as características tivessem a mesma influência inicial no treinamento dos modelos, o conjunto de dados foi normalizado (padronizado) pela técnica de Z-score. Essa técnica é usada para que cada característica seja apresentada na mesma escala de forma adimensional.

A expressão para o Z-score é dada pela Equação (1).

$$Z_s = \left(\frac{\text{valor} - \mu}{\sigma} \right) \quad (1)$$

onde μ e σ representam a média e o desvio padrão, respectivamente, da característica a ser normalizada. O efeito da expressão dada pela Equação (1) é padronizar os desvios ou colocá-los em uma escala comum (Blair; Taylor, 2013).

Para a execução de todas as etapas da análise estatística, desde o tratamento inicial dos dados até a geração dos gráficos finais, optou-se pela utilização da linguagem de programação Python. Esta decisão baseia-se no status do Python como uma das principais ferramentas para a ciência de dados, amplamente consolidada na comunidade acadêmica e de pesquisa (Bruce; Bruce; Gedeck, 2020; McKinney, 2017). O poder da linguagem é potencializado por um ecossistema de bibliotecas de código aberto, das quais foram utilizadas: Pandas, para a organização dos *dataframes*; NumPy, para computação numérica de alta performance; SciPy e Statsmodels, para a aplicação dos testes de hipóteses e modelos estatísticos; e as bibliotecas Seaborn e Plotly, para a elaboração de visualizações de dados estáticas e interativas, respectivamente.

3.2 Modelagem Matemática

Uma perspectiva valiosa para compreender fenômenos complexos é por meio de estruturas de representação, conhecidas como modelos, que captam a essência da realidade, embora com variados graus de proximidade. Entre essas estruturas, os modelos matemáticos são amplamente utilizados, buscando traduzir a realidade por meio de equações matemáticas.

No entanto, é imprescindível ressaltar que todo modelo, independentemente de sua forma, é apenas uma simplificação da realidade. Além dos modelos matemáticos, há uma variedade de abordagens de modelagem, incluindo modelos conceituais, mentais, verbais, físicos, estatísticos, lógicos, gráficos e outros. Essas diversas modalidades proporcionam perspectivas complementares e abrangentes na análise e interpretação dos fenômenos em estudo (Cobelli; Carson, 2008).

Segundo, Cobelli e Carson (2008), derivar o modelo é um processo de transformação, conforme ilustrado na Figura 2, sendo que esta transformação é obtida por meio de uma metodologia apropriada.

Figura 2 – Metodologia de modelagem: transformando um sistema em um modelo



Fonte: o autor.

A formulação e o nível de detalhamento de um modelo são altamente influenciados pelo seu propósito. Considerando uma perspectiva científica básica, os modelos se enquadram em quatro categorias principais, cada uma correspondendo a diferentes propósitos gerais: descritivos, interpretativos, preditivos e explicativos (Cobelli; Carson, 2008). Essas categorias refletem as diversas abordagens adotadas na construção e utilização dos modelos, proporcionando uma estrutura flexível para a investigação e compreensão de fenômenos complexos.

Para desenvolver um modelo matemático, uma abordagem viável é trabalhar com dados experimentais. Isso implica explorar descrições quantitativas de sistemas fisiológicos, com base em informações de entrada ou saída obtidas a partir de dados experimentais coletados. A validação de um modelo envolve, principalmente, avaliar se ele atende adequadamente ao propósito para o qual foi criado. Uma vez que um modelo é, por definição, uma representação simplificada da realidade, é importante reconhecer que ele não será capaz de capturar todas as características comportamentais de um sistema real (Cobelli; Carson, 2008).

É de extrema importância que sejam desenvolvidos modelos preditivos confiáveis e que estes busquem descrever os mecanismos subjacentes que levam o indivíduo a desenvolver a DP, como no trabalho proposto por Kuznetsov e Kuznetsov (2016), e modelos capazes de detectar a DP em seu estágio inicial. É possível observar na literatura (Islam; Abdel-Raheem;

Tarique, 2022; Karabayir et al., 2020; Meigal et al., 2013; Rehman et al., 2019) trabalhos que apresentam ferramentas capazes de criar tais condições.

3.3 Análise de Dados e Processamento de Sinais


Esta seção traz uma breve fundamentação teórica sobre a importância de se pensar e estruturar a análise de dados para um projeto, além de uma revisão ao processamento de sinais, já que este é extremamente relevante para a validação dos objetivos propostos no trabalho.

3.3.1 Análise de Dados

Os dados podem ser fatos ou números dos quais conclusões podem ser tiradas. A partir do momento em que os dados foram registrados, classificados e organizados, relacionados e interpretados dentro de uma estrutura para que o significado emergja, eles se tornam informações (Chan, 2015).

O fluxograma simplificado, apresentado na Figura 3, mostra como os dados brutos são transformados em informações.

Figura 3 – Processo de transformação de dados em informação



Fonte: o autor.

No MATLAB, o processamento dos sinais inicia com o carregamento dos arquivos de coleta, onde cada um contém as séries temporais dos participantes. Após a leitura, são selecionadas as colunas correspondentes aos sinais de interesse, como aceleração e força. Esses sinais passam por uma etapa de padronização (do inglês, *standardization*). Esse processo consiste em subtrair a média μ e dividir o resultado pelo desvio padrão σ do sinal. Isso garante tanto a remoção do componente DC (centralizando o sinal em média zero) quanto o escalonamento pela variância (desvio padrão unitário), permitindo comparações mais consistentes entre diferentes participantes e coletas.

Depois dessa normalização, os sinais estão prontos para a extração de características. O código calcula métricas no domínio do tempo que descrevem a forma e a variabilidade dos sinais, como o valor absoluto médio (MAV), suas variações em relação a diferenças ou

derivadas (MAVFD, MAVSD), o valor de pico, o desvio padrão da força, a amplitude (RANGE) e versões normalizadas dessas medidas. Além dessas, são extraídas também características relacionadas ao movimento biomecânico, obtidas por meio de funções específicas que estimam inclinação, trabalho e carga durante a extensão e a flexão, separadamente.

Por fim, todas essas informações são organizadas em uma tabela de características, onde cada linha corresponde a um participante e cada coluna a uma métrica calculada. Essa matriz final constitui a base de dados que pode ser utilizada posteriormente em análises estatísticas, modelagem preditiva ou algoritmos de aprendizado de máquina.

Para a filmagem do movimento de flexão e extensão, espera-se que a análise das gravações proporcione resultados relacionados à variação angular do movimento. A partir dessas análises, será possível gerar tabelas contendo a relação entre o tempo e a variação angular observada em cada voluntário, tanto do grupo controle quanto do grupo de pessoas com DP. Essa abordagem permite não apenas quantificar a amplitude e a velocidade do movimento, mas também avaliar a regularidade e a coordenação motora, aspectos frequentemente comprometidos em indivíduos com a doença. Dessa forma, a coleta sistemática dos dados fornece uma base objetiva para comparações entre grupos e para a identificação de padrões específicos associados às alterações motoras.

De forma prática, a análise dos dados viabiliza a determinação dos parâmetros essenciais para a construção de modelos que representem o fenômeno em estudo, permitindo traduzir o movimento humano em descrições matemáticas que possam ser analisadas e comparadas. Como destacado por Huang et al. (1998), essa modelagem contribui para a compreensão do problema e pode servir como subsídio para o desenvolvimento de estratégias de intervenção, avaliação clínica e até mesmo de sistemas de apoio diagnóstico em contextos biomédicos.

3.3.2 Processamento de Sinais

De modo a facilitar o entendimento sobre o processamento de sinais, já que o assunto é amplo e extremamente vasto na literatura, alguns tópicos aqui abordados serão brevemente apresentados de modo a destacar apenas suas características principais.

Ao falar dos dados obtidos de processos físicos naturais, é importante destacar que tais processos, na maioria dos casos, são não-lineares e não estacionários; e, desta forma, as técnicas convencionais de processamento de sinais podem oferecer uma abordagem limitada para a análise desses processos (Santos et al., 2020).

Como para a análise de dados se faz necessário o processamento de sinais, o qual tem por objetivo minimizar erros, melhorar a qualidade do sinal e a própria estabilidade do sistema, é possível, a partir do uso de diversas ferramentas, extrair e selecionar características do sinal para posteriormente analisá-lo, como representado na Figura 3.

Segundo Santos (2020), uma vez tendo sido realizada a medição dos sinais, é possível aplicar técnicas de processamento de sinais que permitem automatizar o processo de diagnóstico de discontinuidades, eliminando possíveis imprecisões devido a erros durante a operação de obtenção do sinal e, desta forma, aumentando a eficácia do diagnóstico.

Por exemplo, na medicina, a geração de sinais biomédicos a partir de sistemas fisiológicos, possibilita a extração de informação sobre a complexidade do sistema a partir das séries temporais derivadas, como registros contínuos de eletroencefalograma e eletromiograma, valores batimento a batimento de variáveis cardiovasculares entre outras, que contribuem para a exploração e monitoramento desses sistemas e sua condição de saúde ao longo do tempo, além de permitir a predição de possíveis efeitos patológicos (Castiglioni; Faes; Valenza, 2020).

Para processar os sinais, é necessário entender sua natureza, classificá-los para esclarecer os limites da análise e das expectativas. Então, vários subsídios podem vir à mente e pode ser que quase todos os sinais variem aleatoriamente e continuamente ao longo do tempo (Chaparro; Akan, 2018). Ainda, segundo os autores, a representação matemática de sinais significa a forma de se imaginar um sinal em função do tempo, espaço ou tempo e espaço, sendo então oferecida uma classificação do sinal relacionada a como este é armazenado, processado ou ambos.

3.4 Modelos de Aprendizagem de Máquina

O Aprendizado de Máquina (AM) (do inglês *Machine Learning* – ML) é um subcampo da inteligência artificial (IA) (do inglês *Artificial Intelligence* - AI) que estuda a capacidade de computadores aprenderem com experiências anteriores (Friedman; Hastie; Tibshirani, 2001). Tem sido aplicado em diversas áreas, sobretudo, na medicina. Como todo objeto de investigação científica, a IA inclui técnicas que permitem às máquinas copiarem o comportamento humano por meio de algoritmos que auxiliam a máquina no processo de aprendizagem e na classificação de padrões, de forma rápida e segura (Goecks et al., 2020). Por outro lado, o ML, como parte integrante da IA, refere-se a uma ampla gama de algoritmos e metodologias que possibilitam aos *softwares* melhorar seu desempenho à medida que obtêm um volume maior de dados. Dentre essas técnicas, é possível citar redes neurais, aprendizagem

profunda, árvores de decisão, hipóteses bayesianas, mapas auto-organizáveis, instâncias de aprendizado, modelos de Markov e a computação cognitiva (Jordan; Mitchell, 2015).


Os modelos de ML são elaborados com base em conjuntos extensos de dados e treinados por meio de abordagens matemáticas e estatísticas. Esses modelos têm a capacidade de classificar, agrupar e prever novos dados. Geralmente, os algoritmos de ML mais utilizados são classificados em três métodos de aprendizado: supervisionado, não supervisionado e por reforço (Arulkumaran et al., 2017; Goecks et al., 2020). O aprendizado de máquina compreende um conjunto de métodos projetados para identificar automaticamente padrões nos dados e, posteriormente, utilizar esses padrões para prever eventos futuros ou tomar decisões mais assertivas.

Diante dos avanços da tecnologia e do poder computacional, os modelos de ML tem emergido como uma ferramenta valiosa por meio da análise de grandes conjuntos de dados relacionados a tratamentos e desfechos clínicos, proporcionando o auxílio ao diagnóstico precoce e à predição de novos dados, além de individualizar tratamentos e realizar o monitoramento contínuo em apoio à saúde geral, contribuindo assim para a melhoria na qualidade de vida do paciente (Arulkumaran et al., 2017; Goecks et al., 2020).

O uso de algoritmos como Random Forest (RF), Support Vector Machine (SVM), K-Nearest Neighbor (KNN) e Naïve Bayes (NB) ajudou a diferenciar tremores de DP de tremores essenciais a partir de dados obtidos por meio dos registros de sensores inerciais, como pode ser observado na literatura (Peres et al., 2021).

A Figura 4 apresenta um diagrama dos principais tipos de aprendizado de máquina, divididos entre métodos supervisionados, que utilizam dados rotulados (classificação e regressão), e não supervisionados, que operam sem rótulos (clusterização e redução de dimensionalidade). Para uma compreensão detalhada de toda a hierarquia desses algoritmos, incluindo a abordagem de aprendizado por reforço (*reinforcement learning*), pode ser observada no trabalho de Rashidi et al. (2019).

Figura 4 – Diagrama sobre o AM para os métodos supervisionado e não supervisionado.



Fonte: o autor.

Neste contexto, algoritmos de ML podem criar condições para identificar variáveis relevantes que representem informações valiosas sobre pacientes com DP, permitindo tanto a classificação que auxiliaria no diagnóstico quanto a predição que possibilitaria antecipar a progressão clínica, estimar o risco de eventos como, por exemplo, quedas, prever a resposta a intervenções farmacológicas e de reabilitação, além de orientar o ajuste individualizado do tratamento.

3.4.1 Aprendizado Supervisionado

No método de aprendizagem supervisionada, o algoritmo recebe um conjunto de dados rotulados, ou seja, variáveis de entrada que caracterizam os dados e o rótulo esperado para a variável de saída. Em seguida, o algoritmo utiliza o treinamento de dados para descrever uma função que associa entrada com saída, ou seja, o método distingue uma entrada desconhecida com base nos parâmetros de treinamento anteriores. De forma resumida, o aprendizado supervisionado é um método que visa aprender um modelo a partir de dados de treinamento rotulados, o que permite fazer previsões sobre dados desconhecidos ou futuros. Considera-se na aprendizagem supervisionada a existência de duas principais categorias: a classificação da

aprendizagem supervisionada, na qual os dados de entrada produzem uma saída discreta, ou a abordagem de regressão, que envolve a aquisição cumulativa de dados para produção numérica contínua (Rashidi et al., 2019).

O algoritmo empregado na aprendizagem supervisionada concentra-se principalmente em dois aspectos: (i) classificação, que determina a categoria ou grupo ao qual uma nova observação pertence, com base em dados de treinamento que contêm atributos ou características cuja associação com a categoria é conhecida; e (ii) regressão, que estima valores contínuos para uma nova variável, utilizando instâncias de treinamento com valores conhecidos dessa variável (Handelman et al., 2018).

Ao se considerar a tarefa de classificação, ela pode ser binária, em que os algoritmos conseguem distinguir, por exemplo, duas classes possíveis: indivíduos com a DP ou indivíduo saudável. No entanto, é importante ressaltar que a tarefa de classificação pode ser um pouco mais complexa, fugindo do objeto deste trabalho, possuindo várias classes. Por outro lado, a regressão é utilizada quando o objetivo principal é fazer a predição para resultados contínuos, sendo definidos um conjunto de variáveis preditoras e uma variável de resposta contínua de modo que o algoritmo por meio de uma correlação entre as variáveis seja capaz de realizar a predição da variável de resposta (Rashidi et al., 2019).

3.4.2 Aprendizado Não Supervisionado

No método de aprendizado não supervisionado, os algoritmos não têm conhecimento prévio da saída esperada para cada amostra do conjunto de dados. Isso ocorre porque o conjunto de treinamento não possui rótulos associados às características, sendo representado apenas pela Equação (2) (Suthaharan, 2016):

$$D = \{(x_k)\}_{k=1}^n \quad (2)$$

onde x denota um objeto descrito por k características, com $k = 1, 2, 3, \dots$

Neste método de aprendizagem, o objetivo principal é explorar maneiras de descrever os dados, como agrupando as amostras em conjuntos ou identificando associações entre seus atributos (Marsland, 2015). Esse cenário é característico de problemas menos definidos, pois não há um padrão predefinido a ser identificado e não são usadas métricas de erro claras, ao contrário do aprendizado supervisionado, que pode prever y para um determinado valor de x fornecido (Suthaharan, 2016).

Os métodos de aprendizagem não supervisionados dividem suas abordagens em duas categorias de algoritmos. A primeira categoria trata de problemas de agrupamento (*clusters*), cujo objetivo é descobrir os agrupamentos inerentes aos dados. A segunda categoria aborda os problemas de aprendizado de regras de associação, que prospectam a formulação de regras que descrevam grande parte dos dados. Os algoritmos utilizados na aprendizagem não supervisionada, consideram o agrupamento de dados não rotulados para a produção de grupos que possuem certas semelhanças. Nesse caso, o objetivo principal é descobrir padrões relevantes para o estudo e dividi-los em grupos (Rashidi et al., 2019).

Os métodos de aprendizagem mencionados viabilizam o uso de ferramentas, ou seja, algoritmos capazes de realizar previsões precisas para distinguir entre pessoas com DP e pessoas saudáveis. Atualmente, diversos estudos propõem métodos para um diagnóstico mais objetivo da DP, empregando sensores inerciais e classificadores com abordagens semelhantes às apresentadas neste estudo (Juutinen et al., 2020; Sigcha et al., 2023).

No entanto, para alcançar resultados otimizados, é necessário realizar simulações com o objetivo de identificar os parâmetros adequados a serem utilizados em cada um dos classificadores mencionados anteriormente (Peres et al., 2021). Essas simulações visam aprimorar a eficácia dos métodos de aprendizagem, garantindo uma distinção precisa entre pessoas com DP e pessoas saudáveis. Este processo é essencial para melhorar a precisão e a confiabilidade do diagnóstico da DP, alinhando-se aos avanços tecnológicos e metodológicos propostos por estudos semelhantes nesta área.

Diante dos desafios enfrentados no auxílio ao diagnóstico da DP, especialmente em suas fases iniciais, e da subjetividade associada aos métodos diagnósticos convencionais, surge a necessidade premente de introduzir abordagens objetivas para auxiliar na detecção da doença. Nesse sentido, este estudo propõe a análise dos movimentos capturados, considerando a aplicação de uma órtese instrumentada como uma ferramenta promissora para a quantificação da rigidez em pacientes com a DP, bem como para auxiliar no diagnóstico. Essa abordagem representa uma área de investigação crucial, oferecendo um caminho viável para melhorar a precisão e a objetividade do diagnóstico, alinhando-se às demandas e aos avanços da tecnologia atual.

3.4.3 Modelos de Aprendizado de Máquina para o Caso Supervisionado

A utilização de algoritmos de ML poderá auxiliar no processo de identificação de características que possam representar informações sobre a rigidez em indivíduos com DP, por

meio do agrupamento e/ou classificação dos dados, através da extração de características dos indivíduos.

O foco deste trabalho está na aplicação de técnicas de aprendizado supervisionado para auxiliar na identificação da DP, a partir da análise da rigidez do punho. Utilizando os sinais obtidos pela órtese e pelo processamento de vídeo, foi construída uma base de dados com medidas objetivas que servem de insumo para o treinamento dos algoritmos de ML. Esses modelos têm como objetivo reconhecer padrões que diferenciem indivíduos com a DP do grupo de controle.

Além da classificação, espera-se que os algoritmos também sejam capazes de estimar quantitativamente os níveis de rigidez por meio de técnicas de regressão, buscando estabelecer relações entre parâmetros cinemáticos, como variação angular, velocidade e aceleração do movimento, e desfechos clínicos associados. Essa abordagem permitirá não apenas diferenciar indivíduos com DP do grupo controle, mas também fornecer métricas objetivas de severidade, ampliando o potencial de aplicação dos modelos no apoio ao diagnóstico e no acompanhamento da progressão da doença. A seguir, são apresentadas as características principais dos classificadores inicialmente selecionados para este estudo.

3.4.3.1 Regressão Logística (LR)

A regressão logística é um modelo de classificação que se destaca por sua simplicidade de implementação e desempenho consistente em classes linearmente separáveis. É amplamente adotada na indústria como um dos algoritmos mais utilizados para classificação. O modelo de regressão logística considerado neste estudo é uma abordagem linear para classificação binária, que pode ser estendida para classificação multiclasse, por meio de outras técnicas (Raschka; Mirjalili, 2017).

O termo "regressão" pode parecer inadequado, pois, na verdade, este é um método de classificação que emprega uma função logística para prever uma variável dependente alvo. Uma variação desse método, regressão logística multinomial, também pode ser aplicada para classificar mais de dois alvos. Na abordagem binária, a função produz um valor de 0 ou 1, representando os casos negativo (0) e positivo (1). Isso é determinado calculando-se uma razão de chances para atribuir um valor como positivo ou negativo, com base nas relações entre as variáveis independentes de entrada (características) e as variáveis dependentes (alvo). Este algoritmo é amplamente empregado na indústria, como já mencionado por Raschka e Mirjalili (2017), e na área médica, embora seu uso possa ser limitado em situações com grande número de características ou alta correlação entre elas. Além disso, essa abordagem pressupõe que a

relação entre as características e as variáveis dependentes seja uniforme, o que pode limitar o desempenho do modelo (Rashidi et al., 2019).

3.4.3.2 Máquinas de Vetores de Suporte (SVM)

A Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machine*) é um dos algoritmos mais populares na aprendizagem de máquina moderna, introduzido por Vapnik em 1992. Este método ganhou destaque principalmente devido ao seu desempenho impressionante na classificação de conjuntos de dados de tamanho razoável. No entanto, ele não se mostra eficaz em conjuntos de dados extremamente grandes devido à escalabilidade computacional dos cálculos envolvidos, tornando-se dispendioso computacionalmente (Marsland, 2015).

O SVM classifica dados definindo um hiperplano que melhor diferencia dois grupos, maximizando a margem em ambos os lados desse hiperplano. Essa margem representa a região delimitada pelo hiperplano com a maior separação possível. Uma das principais vantagens desse método é sua capacidade de encontrar relacionamentos não lineares através do uso de uma função de kernel, que permite transformar os dados em um espaço dimensional superior, aumentando assim a margem de divisão entre as classes de interesse (Rashidi et al., 2019). Para essa função de mapeamento, são comumente utilizadas funções de kernel, como o kernel de base radial e o kernel polinomial. No entanto, uma limitação do SVM sua alta sensibilidade à escolha dos hiperparâmetros, como o parâmetro de regularização e os parâmetros do kernel (Hastie; Tibshirani; Friedman, 2009; Marsland, 2015; Raschka; Mirjalili, 2017). Como em qualquer modelo de machine learning, uma sintonia inadequada desses parâmetros pode facilmente levar ao *overfitting*, comprometendo a capacidade de generalização do modelo (Rashidi et al., 2019).

3.4.3.3 K-vizinhos mais próximos (KNN)

O algoritmo KNN (do inglês *K-Nearest Neighbors*) é um classificador supervisionado não paramétrico que se baseia no conceito de similaridade para recuperar os vizinhos mais próximos. Ele agrupa um conjunto de pontos de dados em grupos e classifica novos dados com base em uma medida de similaridade, como a distância euclidiana. Sua principal vantagem é que não assume a forma de um modelo ajustado, sendo inteiramente baseado em aprendizado orientado por dados. Tecnicamente, dado um valor k e um vetor de características a serem classificadas, o algoritmo localiza os k vizinhos mais próximos do vetor no conjunto de dados de treinamento e usa as categorias desses vizinhos para determinar a classe do vetor. Isso impõe

uma carga computacional mais baixa, tornando o algoritmo KNN rápido e geralmente preciso (Lahmiri; Dawson; Shmuel, 2018; Rashidi et al., 2019). O algoritmo KNN pode ser simplificado considerando três passos:

- 1) Calcular as distâncias euclidianas entre um novo objeto o e todos os objetos no conjunto utilizado no aprendizado;
- 2) Escolher os k objetos do conjunto de aprendizado que estão mais próximos de o ;
- 3) Classifique-o em relação ao grupo associado ao maior número dos k objetos.

Uma vantagem significativa do KNN é sua capacidade de adaptação imediata conforme novos dados de treinamento são coletados. No entanto, uma desvantagem é o aumento linear da complexidade computacional para classificar novas amostras à medida que o número de amostras no conjunto de dados aumenta, especialmente em conjuntos de dados de muitas dimensões. De modo a garantir o melhor desempenho do algoritmo, a escolha adequada de k é crucial, equilibrando o *overfitting* e o *underfitting*. Além disso, a escolha da métrica de distância é importante, sendo comumente utilizada a distância euclidiana para amostras com valores reais, mas a normalização dos dados é essencial para garantir que todas as características contribuam igualmente para o cálculo da distância. (Raschka; Mirjalili, 2017; Rashidi et al., 2019).

3.4.3.4 Floresta aleatória (RF)

O algoritmo Floresta Aleatória (RF, do inglês *Random Forest*) é uma técnica de aprendizado de máquina que utiliza um conjunto de árvores de decisão para realizar o aprendizado em conjunto. Cada árvore é construída a partir de um subconjunto aleatório dos dados, utilizando a técnica de amostragem *bootstrap*, o que garante independência entre as árvores. Durante a fase de classificação, cada árvore produz uma predição e, por meio de um processo de votação, a classe mais frequente é escolhida como a predição final. Essa abordagem de "voto majoritário" contribui para a robustez do modelo, reduzindo o impacto de sobreajuste e aumentando sua capacidade de generalização (Hastie; Tibshirani; Friedman, 2009; Raschka; Mirjalili, 2017).

A técnica de amostragem aleatória utilizada na Floresta Aleatória permite a construção de múltiplas árvores de decisão de forma eficiente, contribuindo para uma melhor capacidade de generalização do modelo. No entanto, o desempenho do algoritmo pode ser influenciado pela escolha do número de árvores e outros parâmetros internos. Além disso, o processo de avaliação de variáveis pode ser mais demorado em comparação com outros métodos, como os

não paramétricos, por exemplo, SVM e KNN, e os métodos paramétricos, por exemplo a regressão logística (Rashidi et al., 2019).

3.4.3.5 Árvores de decisão (DT)

As árvores de decisão utilizam uma estrutura de fluxograma que tipicamente contém uma raiz, nós internos, ramos e folhas. O nó interno é onde o atributo em questão é testado, enquanto o ramo é onde o resultado dessa questão é delegado. As folhas são onde o rótulo da classe final é atribuído, o que representa a decisão final após a incorporação dos resultados de todos os atributos. O resultado da árvore de decisão é um conjunto de regras que governa o caminho da raiz até as folhas. Embora árvores de decisão, quando usadas isoladamente, muitas vezes não sejam a abordagem de melhor desempenho (Marsland, 2015; Rashidi et al., 2019), elas são um pilar fundamental do ML. Elas servem como blocos de construção essenciais para métodos ensemble de alta performance, como Random Forest e Gradient Boosting (Rashidi et al., 2019). Os classificadores de árvores de decisão são modelos atraentes se nos preocuparmos com a interpretabilidade. Como o nome sugere, este modelo constrói uma estrutura hierárquica, uma ‘árvore’, em que cada nó representa uma pergunta sobre um atributo, cuja resposta divide os dados em caminhos distintos (Raschka; Mirjalili, 2017).

Com base nos recursos do nosso conjunto de treinamento, o modelo de árvore de decisão aprende uma série de perguntas para inferir os rótulos de classe das amostras. Usando o algoritmo de decisão, começamos na raiz da árvore e dividimos os dados no recurso que resulta no maior ganho de informação (IG), que será explicado com mais detalhes na próxima seção. Em um processo iterativo, podemos então repetir esse procedimento de divisão em cada nó filho até que as folhas sejam puras. Isso significa que as amostras de cada nó pertencem todas à mesma classe. Na prática, isso pode resultar em uma árvore muito profunda com muitos nós, o que pode facilmente levar ao *overfitting*. Assim, geralmente queremos podar a árvore, definindo um limite para a profundidade máxima (Raschka; Mirjalili, 2017).

3.4.3.6 Naïve Bayes (NB)

O classificador Naive Bayes é um modelo probabilístico de classificação que se baseia no teorema de Bayes, assumindo a ingênua suposição de independência entre as variáveis preditoras. Esse método calcula a probabilidade de cada classe condicional possível em um conjunto de variáveis preditoras, utilizando a Equação (3) para estimar a probabilidade de um evento ocorrer, dado que um evento B conhecido já aconteceu (Lahmiri; Dawson; Shmuel, 2018; Rashidi et al., 2019).

$$P(A|B) = \frac{P(B|A).P(A)}{P(B)} \quad (3)$$


Embora essa simplificação possa parecer uma desvantagem, na prática, os classificadores Naive Bayes às vezes podem produzir resultados razoáveis, especialmente para tarefas simples. No entanto, estudos demonstraram que seu desempenho tende a ser inferior a alguns dos algoritmos mais estabelecidos, como Árvores Impulsionadas e Florestas Aleatórias (Rashidi et al., 2019).

3.4.3.7 Redes neurais artificiais (ANN)

As redes neurais artificiais (ANN, do inglês *Artificial Neural Network*) são modelos matemáticos não lineares utilizados com o objetivo de imitar a cognição humana, em que as informações são processadas por meio de neurônios biológicos. Elas empregam o aprendizado supervisionado do erro médio quadrático, implementado com um método de descida de gradiente para realizar um mapeamento não linear dos dados. Além disso, as ANN não se baseiam em suposições sobre os dados. Em vez disso, são orientadas pelos dados, sendo assim, quanto maior o conjunto de dados, melhor o desempenho da rede (Lahmiri; Dawson; Shmuel, 2018).

Como já mencionado por Lahmiri et al. (2018), a rede neural artificial é um modelo inspirado em redes neurais biológicas, sendo usado para prever uma função conectada a múltiplas entradas. Basicamente, a ANN foi inspirada em uma rede neural biológica composta por uma grande rede de neurônios interconectados. A estrutura geral das redes neurais artificiais é mostrada na Figura 5.

Figura 5 – Representação da estrutura geral de uma rede neural artificial (ANN).



Fonte: o autor.

Essas conexões são ponderadas com base em experiências passadas; assim, a rede é adaptativa e capaz de aprender. As redes neurais artificiais são amplamente utilizadas em problemas de reconhecimento de padrões e de classificação. Durante o treinamento de ANN, o algoritmo mais apropriado deve ser escolhido para obter a conclusão correta do problema. As abordagens mais amplamente utilizadas na fase de treinamento de redes de múltiplas camadas são o *backpropagation* em lote (BBP), a propagação quintessencial (QP), a descida do gradiente conjugado (CGD) e os algoritmos de treinamento Levenberg-Marquardt (LM) (Yasar et al., 2019).

3.4.3.8 *Análise Discriminante Linear (LDA)*

A Análise Discriminante Linear (LDA, do inglês *Linear Discriminant Analysis*) pode ser utilizada como técnica para extração de características para aumentar a eficiência computacional e reduzir o grau de *overfitting* devido ao desafio da dimensionalidade em modelos não regularizados. O conceito geral por trás da LDA é muito semelhante ao do PCA, que busca encontrar os eixos de componentes ortogonais de máxima variância em um conjunto de dados; o objetivo da LDA é encontrar o subespaço de características que otimiza a separabilidade entre as classes. Uma das suposições na LDA é que os dados seguem uma distribuição normal (Gaussiana) multivariada. Além disso, o LDA assume que todas as classes partilham uma matriz de covariância idêntica, uma suposição conhecida como homoscedasticidade. No entanto, mesmo que uma ou mais dessas suposições sejam (levemente) violadas, a LDA para redução de dimensionalidade ainda pode funcionar razoavelmente bem (Raschka; Mirjalili, 2017).

A LDA tornou-se um método de referência padrão em classificação, devido à sua simplicidade e interpretabilidade. Com base no critério de discriminação de Fisher, ela gera uma matriz de projeção linear utilizada para melhorar a precisão da classificação. Em particular, emprega fronteiras de decisão lineares para maximizar a proporção de variabilidade entre as classes e dentro de cada classe. Essas fronteiras de decisão lineares são obtidas aplicando a decomposição em autovalores às matrizes de dispersão, assumindo que a matriz de dispersão é não singular. De modo mais objetivo, a LDA gera uma função discriminante que separa amostras em dois ou mais grupos, minimizando o custo esperado de classificação incorreta e maximizando a razão das variâncias entre grupos S_b e dentro de grupos S_w (Lahmiri; Dawson; Shmuel, 2018).

3.5 Divisão de Dados

A divisão adequada dos dados é uma etapa fundamental no desenvolvimento de modelos de ML, pois influencia diretamente a capacidade de generalização e a validade dos resultados. Esse processo consiste em separar o conjunto original de amostras em subconjuntos distintos, como apresentado na Figura 6, geralmente destinados ao treinamento e à avaliação do modelo. Essa separação permite mensurar seu desempenho com base em dados não utilizados durante o aprendizado, alocados no subconjunto de teste. No contexto desta pesquisa, voltada à classificação de indivíduos com e sem a DP, a partir de parâmetros relacionados à rigidez, essa estratégia assegura que a análise não seja enviesada por repetições ou por sobreposição de informações entre as etapas de treino e teste.

Além de ser um procedimento amplamente consolidado na literatura de ciência de dados e inteligência artificial (Alshammri et al., 2023; Bao et al., 2022; Özseven; Özkorucu, 2023; Rehman et al., 2019), a divisão dos dados possibilita explorar diferentes configurações de partição, adaptando-se às particularidades de cada estudo, como o tamanho total da amostra, a variabilidade dos sinais e a complexidade dos algoritmos aplicados. Essa flexibilidade é especialmente relevante em cenários biomédicos, nos quais a coleta de dados pode ser limitada e heterogênea, exigindo um balanceamento criterioso entre quantidade de dados para aprendizado e robustez do modelo final.

3.5.1 Divisão em subconjuntos de Treino e Teste


Nota-se na literatura que a divisão dos dados em conjuntos de treino e teste refere-se primeiramente ao tamanho das partições, sendo comum utilizar entre 70% e 80% dos dados para treinamento e entre 20% e 30% para teste (Alshammri et al., 2023; Bao et al., 2022; Islam; Abdel-Raheem; Tarique, 2022; Rehman et al., 2019; Silva et al., 2025b). A proporção dos dados, de treinamento e teste, não é fixa e dependendo da quantidade total de dados disponíveis e da complexidade do modelo, podem ser testadas diferentes divisões, como 90% para treino e 10% para teste, como pode ser observado na literatura (Bao et al., 2022; Rehman et al., 2019). Em alguns trabalhos, são avaliadas múltiplas proporções de divisão (por exemplo, 70/30, 80/20 e 90/10) a fim de identificar qual configuração proporciona o melhor equilíbrio entre capacidade de aprendizado do modelo e desempenho em dados não vistos.

A principal razão para a divisão em um subconjunto de treino e teste é evitar o sobreajuste (*overfitting*), um problema no qual o modelo se ajusta excessivamente aos dados de treinamento e perde a capacidade de generalizar para novos casos, como se tivesse

“memorizado” ou “decorado” o comportamento dos dados em vez de aprender os padrões (Alshammri et al., 2023; Silva et al., 2025a; Tougui; Jilbab; Mhamdi, 2022). Nessa situação, o desempenho em dados conhecidos pode ser elevado, mas a acurácia em dados inéditos tende a cair de forma significativa.

A Figura 6 ilustra o processo de particionamento dos dados em subconjuntos distintos para treinamento e teste dos modelos de ML. Essa separação é fundamental para avaliar a capacidade de generalização do modelo, garantindo que o desempenho obtido não seja apenas resultado do ajuste aos dados já conhecidos, mas também reflita sua efetividade ao lidar com informações ainda não vistas.

Figura 6 – Representação para a divisão dos dados em subconjuntos para o treinamento e teste dos modelos



Fonte: o autor.

A adoção de uma divisão aleatória dos dados traz vantagens importantes para a qualidade do treinamento e para a avaliação dos modelos. Esse procedimento evita que padrões artificiais ou vieses presentes na ordenação original do conjunto de dados influenciem indevidamente o aprendizado, garantindo que cada partição contenha uma representação equilibrada das características da amostra. Além disso, a aleatoriedade aumenta a robustez estatística da análise, reduzindo a probabilidade de que os resultados sejam consequência de uma distribuição particular dos dados, em vez de refletirem a capacidade real de generalização do modelo.

Para assegurar a replicabilidade dos resultados por outros pesquisadores, será utilizada uma semente (*seed*) fixa no processo de amostragem, de modo que a partição dos dados possa ser reproduzida de forma idêntica em execuções futuras (Silva et al., 2025b). Esse cuidado


minimiza vieses na construção e avaliação do modelo, permitindo que os resultados obtidos reflitam de forma mais fidedigna o desempenho esperado em aplicações reais.

3.5.2 Validação Cruzada

A validação cruzada (*cross-validation*) é uma estratégia de reamostragem amplamente empregada para estimar o erro de generalização de modelos supervisionados. O conjunto de dados é particionado em k subconjuntos aproximadamente iguais (*folds*); em cada iteração, um *fold* desempenha o papel de validação enquanto os $k-1$ restantes compõem o treino, como ilustrado na Figura 7. As métricas são então agregadas ao longo das k iterações, fornecendo uma estimativa mais estável e menos dependente de uma única partição dos dados (Hwang et al., 2025; Karabayir et al., 2020; Navita et al., 2025).

Na prática, essa estratégia pode ser utilizada de duas formas complementares e reconhecidas: (i) reservar um conjunto de teste externo (*hold-out*) e aplicar a validação cruzada apenas sobre o subconjunto de treinamento (para seleção de modelos e ajuste de hiperparâmetros), preservando o teste para uma avaliação final e imparcial; ou (ii) empregar validação cruzada aninhada, em que *folds* “externos” simulam o papel do teste enquanto *folds* “internos” são usados para ajuste e seleção. Em ambos os casos, os *folds* são construídos apenas sobre o subconjunto efetivamente utilizado na etapa de seleção, evitando o vazamento de dados (Bruce; Bruce, 2017; Hastie; Tibshirani; Friedman, 2009).

Figura 7 – Esquema de validação cruzada no método *K-fold* considerando $k=5$



Fonte: o autor.

O processo, como ilustrado na Figura 7, é repetido K vezes, garantindo que todas as amostras sejam utilizadas tanto para treino quanto para validação em momentos distintos. As métricas de desempenho obtidas em cada iteração são então agregadas, resultando em uma estimativa mais confiável e estável do desempenho do modelo (Bruce; Bruce, 2017; Hastie; Tibshirani; Friedman, 2009). Essa metodologia contribui para mitigar o *overfitting* e permite avaliar, de forma mais realista, a capacidade do modelo de prever novos casos, aspecto essencial para aplicações clínicas e preditivas. Os parâmetros adotados neste trabalho, como as proporções de divisão, a estratificação e a definição da semente, são apresentados posteriormente na seção de Metodologia e retomados nos Resultados.

3.6 Matriz de Confusão

A matriz de confusão é uma matriz ou tabela de valores reais e preditos que descreve o desempenho do modelo considerado. Cada classe predita é comparada com sua classe real e, então, tem-se quantas amostras foram classificadas erroneamente e quais amostras foram classificadas de forma correta (Joshi; Khajuria; Joshi, 2017). A matriz de confusão construída para avaliar o desempenho dos modelos de ML é apresentada na

Tabela 2, considerando os verdadeiros positivos (VP), falsos positivos (FP), verdadeiros negativos (VN) e falsos negativos (FN).

Tabela 2 – Matriz de confusão para indivíduos saudáveis e com a doença de Parkinson

	Valor Predito	
	Saudável	Doença de Parkinson
Saudável	VN	FP
Doença de Parkinson	FN	VP

Fonte: o autor.

onde VP é o número de positivos verdadeiros, i.e., um diagnóstico positivo para uma pessoa pertencente à classe analisada no caso deste estudo sendo parkinsoniano; VN é o número de negativos verdadeiros, i.e., é um diagnóstico negativo para um indivíduo que não pertence à classe analisada. Já um FP é o número de falsos positivos, onde tem-se um diagnóstico positivo de um indivíduo que não é parkinsoniano e um FN é o número de falsos negativos, ou seja, um diagnóstico negativo de uma pessoa que pertence ao grupo de indivíduos com a DP (Abrahão, 2017; Joshi; Khajuria; Joshi, 2017).

As métricas de desempenho como sensibilidade, especificidade, precisão, acurácia e F1-score, definidas nas Equações (4) - (8), respectivamente, serão calculadas para cada classificador.

$$Sensibilidade = \frac{VP}{VP + FN} \quad (4)$$

$$Especificidade = \frac{VN}{VN + FP} \quad (5)$$

$$Precisão = \frac{VP}{VP + FP} \quad (6)$$

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (7)$$

$$F1 - score = 2 \cdot \frac{(Precisão \times Sensibilidade)}{(Precisão + Sensibilidade)} \quad (8)$$

A medida de sensibilidade de um método, dada pela Equação (4) reflete o quanto este é eficaz em identificar, dentre todos os indivíduos avaliados, aqueles que realmente apresentam a característica de interesse. No caso específico de um paciente com a doença de Parkinson, a sensibilidade mede o quanto o método é capaz de identificar os voluntários que, de fato, apresentam a doença. Já a especificidade, dada pela Equação (5) reflete a competência do método em identificar corretamente os indivíduos que não apresentam a condição de interesse, ou seja, pertencem ao grupo de controle.

A precisão, dada pela Equação (6), refere-se ao grau de dispersão do conjunto de valores obtidos a partir de medições com a mesma característica; quanto menor a dispersão, maior é a precisão. Enquanto isso, a acurácia dada pela Equação (7), é a proximidade do valor experimental com o valor real, a qual apresenta uma proporção direta na autenticidade do resultado obtido com o valor medido. Por último, a métrica F1-score, dada pela Equação (8), combina Precisão e Sensibilidade em um único valor, indicando o equilíbrio do modelo (Guimaraes et al., 2020; Medeiros et al., 2023).

No contexto de ML, a robustez do modelo pode ser verificada por meio da aplicação de diferentes classificadores, tais como LDA, LR, NB e KNN, entre outros. Para tanto, recorre-se a simulações e procedimentos de ajuste de parâmetros, visando identificar configurações mais adequadas para cada algoritmo. A avaliação da acurácia é usualmente conduzida por meio de

técnicas de validação cruzada, comumente iniciadas pelo particionamento em $k = 5$ *folds*, o que permite mensurar a generalização e reduzir o risco de sobreajuste (Peres et al., 2021).

3.7 Biblioteca de aprendizado de máquina em Python de código aberto

Nesta seção, serão apresentadas as principais funções da biblioteca PyCaret, juntamente com os modelos de classificação empregados neste estudo. O objetivo é evidenciar como esses recursos podem contribuir para o diagnóstico da DP, a partir dos dados coletados pela órtese de punho ativa e do registro dos movimentos de flexão e extensão.

3.7.1 Biblioteca de aprendizado de máquina (PyCaret)

No campo do aprendizado de máquina, a linguagem Python dispõe de uma ampla variedade de pacotes, bibliotecas e ferramentas. Entre eles, destaca-se o PyCaret, uma biblioteca de código aberto e de baixo código (*low-code*), desenvolvida para simplificar e automatizar fluxos de trabalho em ML. Essa ferramenta, baseada em programação orientada a objetos, oferece recursos versáteis para etapas como preparação de dados, classificação, regressão, agrupamento, análise de anomalias e séries temporais (Moez Ali, 2020; Tolios, 2022). Sua proposta consiste em reduzir a complexidade do processo, permitindo que centenas de linhas de programação sejam substituídas por poucas instruções (Tolios, 2022). No presente estudo, o PyCaret será explorado e aplicado a um conjunto de dados provenientes de voluntários com DP e de indivíduos do grupo controle HC (HC, do inglês *Healthy Control*), possibilitando a classificação dos participantes a partir dos sinais obtidos por meio da órtese de punho ativa, consolidando-se como um recurso complementar para apoio ao diagnóstico.

3.7.2 Os modelos de classificação do PyCaret

Diversos trabalhos prévios têm evidenciado a eficácia de abordagens supervisionadas em *machine learning* para a classificação de pacientes com a DP (Karabayir et al., 2020; Karapinar Senturk, 2020; Saeed et al., 2024; Tougui; Jilbab; Mhamdi, 2022). Com base nessas evidências, adotou-se uma estratégia de modelagem abrangente, explorando 19 algoritmos distintos a partir do conjunto de classificadores disponíveis na biblioteca PyCaret. O uso de um repertório diversificado de modelos buscou reduzir vieses na seleção destes e assegurar uma análise comparativa robusta, em linha com *frameworks* semelhantes descritos na literatura (Rehman et al., 2019; Silva et al., 2025).

No processo experimental, foram empregados algoritmos de diferentes famílias, abrangendo métodos lineares, probabilísticos, baseados em árvores e redes neurais. Entre eles destacam-se: AdaBoost (ADA), CatBoost (CATBOOST), Decision Tree (DTC), Dummy Classifier (DUMMY), Extra Trees (ETC), Extreme Gradient Boosting (XGBOOST), Gaussian Process (GPC), Gradient Boosting (GBC), K-Neighbors (KNN), LightGBM (LGHTGBM), Linear Discriminant Analysis (LDA), Logistic Regression (LR), MLP Classifier (MLP), Naïve Bayes (NB), Quadratic Discriminant Analysis (QDA), Random Forest (RF), Ridge Classifier (RIDGE), Support Vector Machine com kernel linear (SVM) e Support Vector Machine com kernel radial (RBFSVM). Essa diversidade garantiu um panorama abrangente da performance de diferentes paradigmas estatísticos e computacionais aplicados ao problema de classificação da DP.

3.7.3 As principais funções do PyCaret

A preparação dos dados e a avaliação de desempenho em modelos de *machine learning* podem ser realizadas de forma automatizada com o uso da biblioteca PyCaret. Nela, a função `setup` organiza os parâmetros do experimento e aplica validação cruzada a partir de partições predefinidas, fornecendo métricas de desempenho em cada subdivisão do conjunto de dados (Jeancolas et al., 2022; Karabayir et al., 2020; Rehman et al., 2019). A função `create_model`, por sua vez, é responsável pelo treinamento de um classificador específico com base nas condições estabelecidas na etapa de configuração.

A etapa de seleção do algoritmo mais adequado é facilitada pelo uso da função `compare_models`, que executa todos os classificadores disponíveis e apresenta seus resultados em formato comparativo (Moez Ali, 2020; Tolios, 2022). Os modelos são ranqueados de acordo com a métrica de interesse, sendo a acurácia frequentemente utilizada como referência (Rehman et al., 2019; Tougui; Jilbab; Mhamdi, 2022).

Já a função `tune_model` exerce papel central no ajuste de hiperparâmetros, processo essencial para refinar o desempenho do modelo. Conforme apontado por Ali (2020), essa função gera uma grade de resultados com os valores da validação cruzada por *fold*, identificando a configuração mais promissora. Por padrão, a otimização é realizada por meio da técnica de randomized search da biblioteca Scikit-Learn.

3.8 Visão Computacional

Com o intuito de garantir que o indivíduo com DP tenha melhor qualidade de vida e definir o melhor tratamento para cada caso, é necessário o monitoramento da patologia. Após o diagnóstico, consultas ou avaliações periódicas são de suma importância; para isso, abordagens como dispositivos inteligentes que utilizam sensores inerciais ou fornecem gravações de voz e vídeo ao médico, a fim de garantir maior conforto ao paciente (Pereira et al., 2016; Sica et al., 2021; Son; Park; Kim, 2018). Assim, análises de dados obtidos por meio dessas abordagens e de procedimentos fisioterapêuticos, podem fornecer informações importantes acerca do progresso dos sintomas e, conseqüentemente, do estágio da DP.

Dessa forma, ferramentas que possam agregar objetividade a métodos subjetivos, como a UPDRS, ou verificar o progresso de procedimentos fisioterapêuticos mostram-se relevantes tanto para o diagnóstico quanto para o tratamento e o monitoramento da DP. Nesse sentido, o foco da metodologia aqui proposta está na aplicação de ferramentas de visão computacional (VC), com ou sem marcadores, que englobam técnicas de análise de imagens e vídeos, juntamente com algoritmos de inteligência artificial e aprendizado de máquina, para extrair informações relevantes, que possam auxiliar nesses processos relacionados à DP (Baker et al., 2022; Güney et al., 2022; Varalakshmi et al., 2022; Vignoud et al., [S.d.]; Williams et al., 2020).

Visão computacional refere-se ao uso de artifícios computacionais para interpretar e analisar vídeos ou imagens e extrair informações, como o ângulo, a velocidade ou a aceleração de determinada articulação (Williams et al., 2020).

Tratando do uso de técnicas de VC para auxílio no diagnóstico de DP sem o uso de marcadores, Pereira et al. (2016) e Varalakshmi et al. (2022) utilizaram dados caligráficos para alimentar algoritmos de *machine learning* com a finalidade de classificar indivíduos hígidos e acometidos pela doença, atingindo níveis de acurácia de 67% e 98,45%, respectivamente.

Vignoud et al. (2022) replicaram os protocolos da Parte III da MDS-UPDRS, mais especificamente os itens 3.4 (bater dos dedos da mão em pinça), 3.5 (movimentos da mão) e 3.6 (movimentos de pronação e supinação da mão), gravando o procedimento e, posteriormente, aplicando o vídeo obtido aos algoritmos DeepLabCut (DLC) (Mathis et al., 2018) e HandGraphCNN, obtendo coeficientes de determinação de 0,609 para o bater dos dedos com 0,701 para os movimentos da mão e 0,630 para pronação e supinação da mão. Contudo, reforçam a necessidade da aplicação do protocolo a mais pacientes para a validação do modelo proposto.

Williams et al. (2020) também fizeram uso do DLC aplicado ao item 3.4 da MDS-UPDRS, comparando os dados obtidos pela rede neural utilizada às avaliações de neurologistas, chegando a um coeficiente de correlação de Spearman de 0,69 ($p < 0,001$). Os autores reforçam a possibilidade da reprodução da metodologia considerando os estados de on e off da medicação dopaminérgica para melhor adequar o modelo.

Diferentes trabalhos abordam a análise da marcha em pacientes com DP (Li et al., 2022; Nieto-Hidalgo et al., 2018), utilizando diversas abordagens, como OpenPose ou OpenCV, normalmente correlacionando valores obtidos por meio de técnicas de visão computacional com escalas de diagnóstico, como a MDS-UPDRS (Chen et al., 2012; Ruppachter et al., 2021). Contudo, Ruppachter *et al.* (2021) relatam que não foram considerados indivíduos saudáveis. Chen *et al.* (2012) relatam uma correlação de 0,92 entre o resultado da análise do discriminante linear usada por eles e o escore da parte III da MDS-UPDRS, entretanto, limitando sua análise a anormalidades da marcha.

Referente ao uso de VC como ferramenta de auxílio ao tratamento da DP, Baker et al. (2022) também utilizaram o DLC, entretanto, para uma otimização do posicionamento dos eletrodos da DBS, atingindo valores de acurácia entre 91,50% e 94,50% para a detecção dos gestos analisados. Os autores, no entanto, reforçam a necessidade da replicação dessa metodologia em mais pacientes, assim como a análise de mais tipos de gestos além dos dois utilizados (fechar as mãos e um gesto similar a puxar uma corrente, flexionando o cotovelo).

Güney *et al.* (2022) utilizaram o algoritmo de VC MediaPipe para fazer uma análise da frequência e da amplitude do movimento da mão antes e depois de tomar um medicamento dopaminérgico, concomitantemente a um acelerômetro, no intuito de verificar a viabilidade do método proposto. Os autores chegaram a correlações de 0,98 para a frequência e 1 para a amplitude, detectando a diminuição da frequência e da amplitude do movimento da mão após a ingestão do medicamento.

No contexto das técnicas empregadas em visão computacional, destaca-se o uso do espaço de cores HSV (HSV, do inglês *Hue, Saturation, Value*), amplamente adotado em aplicações de segmentação e rastreamento de objetos. Tal abordagem mostra-se vantajosa por apresentar maior correspondência com a percepção humana das cores quando comparada ao espaço RGB, que mescla informações de crominância e luminância e, por isso, pode ter seu desempenho comprometido diante de variações de iluminação. A representação no formato HSV separa de forma explícita os componentes relativos à tonalidade (matiz) e à intensidade luminosa (valor), favorecendo a robustez da detecção em cenários complexos (Shafi, 2021; Shaik et al., 2015). Evidências na literatura indicam que essa característica se traduz em ganhos

de desempenho em métricas como PSNR (do inglês *Peak Signal to Noise Ratio*) e MSE (do inglês *Mean Squared Error*), além de maior precisão na identificação de regiões de interesse e contornos de objetos, mesmo na presença de sombras, reflexos ou variação de brilho (Bora; Kumar Gupta; Khan, 2015; Hema; Kannan, 2019). Por sua versatilidade e consistência nos resultados, o HSV, frequentemente aliado a algoritmos de processamento de imagem, tem sido empregado em diferentes domínios, incluindo vigilância, segurança, interação humano-computador e classificação de imagens, consolidando-se como uma solução recorrente e confiável em pesquisas e aplicações industriais em visão computacional.

Nota-se na literatura o uso do Kinovea para análise de movimento em 2D e que vem ganhando destaque na área da saúde por sua acessibilidade e precisão na mensuração de parâmetros clínicos importantes, como ângulos articulares e distâncias. Estudos têm demonstrado que o Kinovea apresenta alta confiabilidade tanto intra quanto interavaliadores, com coeficientes de correlação intraclass (ICC) frequentemente superiores a 0,9 para medidas de quadril, joelho e tornozelo durante a marcha, além de forte concordância com sistemas de análise tridimensional considerados padrão-ouro (Iijima; Shiomi; Hara, 2023; Puig-Diví et al., 2019). A facilidade de uso, o baixo custo e a possibilidade de aplicação em diferentes contextos favorecem seu uso em ambientes clínicos e de pesquisa, viabilizando avaliações objetivas que auxiliam na reabilitação e no acompanhamento de intervenções terapêuticas (Fernández-González et al., 2020; Puig-Diví et al., 2019)tal., 2019).

No contexto da doença de Parkinson, o Kinovea tem sido aplicado na análise e no modelamento do padrão de marcha de pacientes, contribuindo para a identificação de alterações características, como redução do comprimento do passo, diminuição da amplitude de movimento e episódios de *freezing* (bloqueio motor) (Soto et al., 2020). Utilizando o Kinovea, é possível extrair dados cinemáticos a partir de vídeos comuns, sem a necessidade de equipamentos especiais, o que facilita a avaliação frequente e o acompanhamento próximo da evolução funcional desses indivíduos.

Em pesquisas recentes, modelos matemáticos validados a partir dos dados coletados pelo *software* permitiram até mesmo diferenciar padrões de marcha entre pacientes com e sem tremor essencial, destacando o potencial do Kinovea como ferramenta de suporte para o desenvolvimento de dispositivos e estratégias de reabilitação personalizadas para pessoas com Parkinson (Soto et al., 2020).

4. MATERIAIS E MÉTODOS

Este capítulo descreve detalhadamente os materiais utilizados e os métodos adotados ao longo do desenvolvimento da pesquisa. A apresentação inicia-se pela caracterização da arquitetura de *hardware* desenvolvida, seguida pelos dispositivos e *softwares* empregados, além das condições experimentais de coleta. Posteriormente, são descritos os procedimentos de processamento de sinais, seleção de variáveis e aplicação de modelos de aprendizado de máquina.

4.1 Materiais

A descrição dos *softwares*, das linguagens de programação e da órtese utilizadas neste trabalho serão apresentados nas subseções seguintes.

4.1.1 Arquitetura e organização do *hardware* personalizado para coleta de dados.

Todos os componentes da órtese de punho ativa, utilizados para avaliação da rigidez, foram desenvolvidos no laboratório NIATS da UFU. A órtese ativa foi patenteada sob o número BR1020140232826. O sistema é composto por cinco unidades principais:

- (i) *hardware* e *software* personalizados para a medição da força, visualização de dados em tempo real e armazenamento de dados;
- (ii) uma ferramenta para a avaliação da força necessária ao movimento de extensão e flexão do punho;
- (iii) uma ferramenta para a avaliação da corrente necessária ao movimento de extensão e flexão do punho;
- (iv) extração de características, organização de dados e armazenamento em uma planilha;
- (v) Celular que será utilizado para gravação da atividade para análise da angulação por meio de ferramentas de visão computacional.

A seguir, são apresentados mais detalhes sobre o *hardware* e o *software* utilizados na órtese de punho.


4.1.2 Hardware utilizado para avaliação da rigidez

A coleta de dados utilizará uma órtese de punho ativa desenvolvida no NIATS, que apresenta as seguintes características:

- Massa: 850 g;
- Atuador: servomotor linear DC, LM 2070-080-11 (Faulhaber, Alemanha);
- Controlador: controlador de alta precisão MCLM 3006 S (Faulhaber, Alemanha).

As partes da órtese são mostradas na Figura 8 e identificadas pelos números de 1 a 8:

Figura 8 – Identificação das partes que compõem a órtese de punho ativa



Fonte: Adaptada de (Costa; Andrade, 2020)


sendo: (1) atuador, (2) eixo cilíndrico do atuador, (3) Eixos cilíndricos auxiliares desenvolvidos para dar mais estabilidade ao movimento do atuador, (4) Case do atuador, (5) Estrutura que se fixa ao antebraço, (6) Limitador de deslocamento usado para segurança, (7) estrutura que se acopla a mão e (8) Juntas esféricas que permitem movimento multidimensional da mão.

A medição da rigidez proposta, baseia-se na força necessária para execução dos movimentos de extensão ou flexão do punho, realizados automaticamente por meio de um servomotor presente na órtese. A órtese dispõe internamente de um sensor de corrente para monitorar a corrente consumida pelo motor, que é proporcional ao deslocamento da haste do motor (Perera et al., 2019). Tal corrente também é proporcional à força exercida pelo motor, por meio de uma constante, como analisado por Ribeiro (2023).

O deslocamento angular será de acordo com o comando enviado ao servomotor. O microcontrolador utilizado no estudo é o MCLM 3006 S RS, um dispositivo altamente dinâmico, projetado para controlar a posição de motores lineares equipados com sensores Hall

analógicos. Esse controlador, representado na Figura 9, regula tanto a posição quanto a velocidade, através do controle preciso da corrente fornecida ao atuador.

Figura 9 – Microcontrolador MCLM3006 S RS e atuador LM1247-060-01 no dispositivo projetado para acomodação, impresso em PLA com estrutura adicional para um atuador de menor potência.



Fonte: o autor.

(A) Vista aérea da base com o microcontrolador MCLM 3006 S RS e o atuador LM 1247-060-01 já fixados em suas respectivas acomodações. (B) Vista superior da base fechada, evidenciando as aberturas estrategicamente posicionadas para a conexão dos cabos, garantindo a integridade das interligações.

A base para acomodação do microcontrolador MCLM 3006 S RS e do atuador LM 1247-060-01 foi desenvolvida em *software* de modelagem e impressa em PLA (ácido polilático) por meio de tecnologia 3D. O projeto dessa estrutura visou otimizar a funcionalidade e a segurança operacional do sistema, que será empregado em trabalhos futuros e atividades de treinamento para uso do *software* e melhor controle do atuador. Especificamente, a base foi concebida para proteger os dispositivos contra contatos indevidos e danos externos, além de garantir a ventilação e o resfriamento adequados do microcontrolador por meio de sulcos laterais, aspecto crucial para seu desempenho.

Adicionalmente, a base facilita o transporte seguro do sistema para diferentes ambientes e assegura a integridade das conexões dos cabos, graças a uma abertura específica na tampa que mitiga a perda de dados ou inconsistências geradas por interligação inadequada. Este último


ponto é fundamental para a obtenção de dados precisos e confiáveis, essenciais para os processos de calibração e validação da órtese.

4.1.3 Softwares utilizados

4.1.3.1 Sistema de Controle e Aquisição de Dados da Órtese

A interação entre o *software* e o controlador realiza-se através de comandos no formato ASCII, os quais são enviados pela porta serial. Esse processo ocorre tanto pelo terminal do *software* Motion Manager quanto através de um arquivo contendo as instruções destinadas ao controlador. A comunicação estabelece-se via RS232, utilizando um cabo conversor RS232-USB para conectar o computador ao controlador. Os comandos enviados são recebidos pelo controlador, que os executa, capturando informações dos sensores Hall do motor e transmitindo-as de volta ao Motion Manager. Todos os dados são transferidos para o computador a uma taxa de 38.400 bits por segundo. É justamente por essa interface gráfica, representada na Figura 10 que são obtidos os valores da corrente consumida pelo motor e do deslocamento da haste.

Figura 10 – Interface do Motion Manager, com um exemplo de dados coletados



Fonte: (FAULHABER, 2023)

Na interface de usuário é possível alterar os parâmetros dos sensores Hall do atuador, controlando as componentes proporcional, diferencial e integral, os quais irão determinar a

velocidade e a precisão com que o atuador tentará atingir a posição requisitada, similar a como escrever um *script* para a coleta, determinando a velocidade e a aceleração que a haste móvel deve ter, e para qual posição ele deve ir. Na Figura 10, é possível observar uma área onde se observa a captura dos dados de corrente consumida pelo motor e a posição da haste, em função do tempo, tais dados são os sinais de interesse para a extração das características a serem utilizadas neste trabalho.

4.1.3.2 Softwares utilizados para análise do vídeo: Kinovea, Adobe After Effects e Python.

O Kinovea é um *software* de análise de movimento bidimensional, gratuito e de código aberto, amplamente reconhecido por sua utilidade em pesquisas científicas que envolvem a avaliação cinemática de movimentos humanos. Sua simplicidade operacional, aliada à capacidade de mensurar ângulos, distâncias e coordenadas a partir de vídeos em alta definição, o torna uma alternativa viável e de baixo custo em relação a sistemas tridimensionais mais complexos e dispendiosos, como o VICON® ou o Hawk-Cortex. Nesta pesquisa, foram selecionados três pontos para determinar o ângulo entre eles, o que permitiu quantificar o deslocamento angular do punho em função do tempo. Contudo, adversidades foram encontradas na determinação confiável e precisa dos ângulos, devido às sombras decorrentes da movimentação da órtese. Essa sombra causava deslocamento dos pontos de referência, tornando a aferição dos ângulos imprecisa.

No intuito de contornar o percalço observado em relação à sombra causada pela órtese, foi necessário adicionar marcadores no processo estiloide da ulna, a referência utilizada para definir a variação angular do punho em relação ao eixo cotovelo-processo estiloide. Para isso, foi utilizado o *software* Adobe After Effects para o rastreamento de pontos (Koehnsen; Kambach; Büsse, 2020), permitindo a sobreposição de um marcador que acompanhasse o deslocamento do processo estiloide ao longo da filmagem. Essa abordagem permitiu a manutenção de uma referência anatomicamente correta, independentemente de variações antropométricas entre os participantes, pois o eixo cotovelo-estiloide seria o mesmo para todos os voluntários. Além disso, foram realizados procedimentos de anonimização e ajustes de cor na vestimenta dos voluntários, a fim de não comprometer a acurácia do rastreamento dos marcadores nem a privacidade dos participantes.

A dificuldade no rastreamento preciso dos marcadores já era, em certa medida, esperada, considerando as características específicas dos voluntários da amostra, como a sensibilidade cutânea e a amplitude variável dos movimentos, bem como o efeito de sombra gerado pela órtese. Além disso, limitações semelhantes já haviam sido descritas por Costa (2020), que

relatou perdas frequentes na detecção dos marcadores reflexivos pelo *software* de captura, atribuídas a movimentos involuntários (discinesias) e posturas adotadas pelos participantes durante as coletas, o que demandou repetições do procedimento e gerou maior desgaste físico nos voluntários. Esse histórico reforça a necessidade das adaptações metodológicas adotadas nesta pesquisa, como a digitalização e padronização dos marcadores via *software*.

Após as etapas de anonimização, padronização e inserção dos marcadores por meio do *software* Adobe After Effects e do *software* próprio construído para esse objetivo, foram realizados testes no programa Kinovea para análise da variação angular do punho. Durante esses testes, observou-se que a coloração original dos marcadores dificultava o reconhecimento automático pelo *software*, comprometendo a precisão das medições. Para contornar esse problema, desenvolveu-se um código em Python, cuja função principal é identificar os marcadores azuis posicionados nos voluntários e sobrepor círculos vermelhos sobre eles, aumentando o contraste e facilitando o rastreamento no *software* Kinovea. O código executa a detecção dos marcadores com base em parâmetros de cor calibrados e aplica a substituição automática para vermelho puro (255, 0, 0) no padrão RGB, garantindo maior precisão na leitura dos movimentos.

Todo o fluxo de funcionamento do algoritmo, incluindo etapas como seleção da região de interesse (ROI), calibração interativa e processamento quadro a quadro, é descrito com maior riqueza de detalhes na Seção 4.2 deste estudo. Essas etapas demonstram o cuidado metodológico empregado para assegurar a reprodutibilidade dos dados extraídos, minimizando interferências externas e maximizando a confiabilidade dos resultados obtidos na análise cinemática. Desta forma, a utilização do Kinovea nesse contexto permitiu a extração precisa de dados angulares sem a necessidade de sensores ou marcadores sofisticados.

A filmagem foi realizada em perspectiva ortogonal ao plano de movimento, o que aumenta a confiabilidade das medidas obtidas, conforme recomendações da literatura (Puig-Diví et al., 2019; Soto et al., 2020). Com base nas imagens capturadas, foi possível avaliar quadro a quadro o comportamento cinemático da articulação do punho, auxiliando na detecção de padrões motores característicos da rigidez muscular associada à doença. Tal abordagem é relevante para compreender a biomecânica do movimento em pacientes com Parkinson e contribui diretamente para a avaliação da resposta a tratamentos ou intervenções terapêuticas.

A literatura apresenta diversos estudos que atestam a confiabilidade do Kinovea para análises biomecânicas, especialmente em contextos clínicos e experimentais (Kawamura, 2023; Puig-Diví et al., 2019; Soto et al., 2020). Embora possam ocorrer variações pontuais entre avaliadores, especialmente em contextos com pouca padronização, os níveis de erro reportados

nas medições angulares com o *software* situam-se, em geral, entre $\pm 2,5^\circ$ e $\pm 5^\circ$, sendo considerados clinicamente aceitáveis. Esses valores tornam-se ainda mais confiáveis quando são adotadas metodologias rigorosas de posicionamento da câmera, plano de filmagem ortogonal e critérios padronizados para rastreamento e análise do movimento. Assim, o Kinovea se consolida como uma ferramenta válida e acessível para investigações que envolvem avaliação de rigidez, especialmente quando associada à Doença de Parkinson (Fernández-González et al., 2020; Iijima; Shiomi; Hara, 2023), possibilitando a extração de parâmetros objetivos com alta reprodutibilidade.

4.1.3.3 Matlab e Python

O tratamento inicial dos sinais captados pela órtese foi realizado no *software* MATLAB, versão estudante R2023b, amplamente reconhecido por suas ferramentas avançadas de processamento de sinais e por sua interface gráfica intuitiva. Após essa etapa de pré-processamento e organização dos dados, as análises estatísticas e as modelagens subsequentes foram desenvolvidas na linguagem de programação Python, selecionada por sua robustez, legibilidade e ampla gama de bibliotecas voltadas à análise científica.

A versão empregada neste estudo foi a Python 3.12.3, escolhida por apresentar melhorias significativas de desempenho e estabilidade em relação às versões anteriores. O ambiente de desenvolvimento foi configurado no Visual Studio Code na versão 1.103.2, em sistema macOS Sonoma 14.5 com arquitetura arm64.

A versão do Python utilizada, associada ao Ambiente de Desenvolvimento Integrado (IDE, do inglês *Integrated Development Environment*) *Visual Studio Code*, contribuiu para uma integração eficiente dos pacotes utilizados, como *Pandas*, *NumPy*, *SciPy*, *Statsmodels* e *Plotly*, essenciais para a análise estatística, testes de normalidade, comparações entre grupos e geração de gráficos interativos, além dos modelos de ML para classificação e regressão disponíveis na biblioteca *PyCaret*. A estabilidade da linguagem e a interface intuitiva da IDE facilitaram o desenvolvimento e a validação dos scripts aplicados. Além disso, por se tratar de uma ferramenta *open source*, favorece a reprodutibilidade científica e o uso acessível de tecnologias robustas no contexto acadêmico.


4.1.4 Validação da órtese

No estudo conduzido por Ribeiro (2023), foi empregada uma regressão linear simples como modelo, uma vez que a análise inicial com regressão polinomial indicou coeficiente nulo para o termo quadrático (x^2), evidenciando uma relação linear entre a força aparente e a força

real, o que tornou desnecessário o uso de modelos de ordem superior. A constante de força real apresentou variação entre 35,76 N/A, observada em menores forças devido a flutuações no valor PID do controlador, e 11,84 N/A, com uma constante média de 14,28 N/A.

Aplicando essa constante aos valores esperados e considerando um intervalo de confiança de 95%, Ribeiro (2023) obteve um p-valor inferior a 10^{-16} para a Força aparente, indicando que variações nessa variável provocam alterações estatisticamente significativas na força real. A Figura 11 apresenta o esquema adotado para a validação da órtese, descrevendo de forma visual as etapas e procedimentos aplicados na verificação de seu desempenho.

Figura 11 – Esboço da abordagem utilizada para validação da órtese



Fonte: Ribeiro, 2023


Tendo as massas conhecidas e as massas calculadas por meio da força peso, pela qual é possível calcular a massa do objeto, Ribeiro (2023) chegou a uma nova constante por meio de uma regressão linear da Força Real com base na Força Aparente: 14,28 N/A, 18,49% maior que a constante de força fornecida pelo manual do motor, que possibilita calcular a força real com base na força obtida pelo software. No entanto, para fins desta tese, os dados originais de Ribeiro (2023) foram reanalisados neste estudo, visando a um maior refinamento e precisão dos coeficientes do modelo. Essa nova regressão linear, que considera um número maior de casas decimais, resultou na Equação (9).

$$\text{Força Real} = 0,3257 + 0,9874 * (\text{Força Aparente}) \quad (9)$$

A Equação (9), gerada nesta análise, apresenta um coeficiente de determinação (R^2) de 0,9995, evidenciando um alto grau de ajuste aos dados analisados. Essa equação difere daquela relatada por Ribeiro (2023).

Da mesma forma, o autor calculou duas equações para determinar o ângulo com base na posição informada da haste do servomotor: uma para a haste em equilíbrio estático e outra para a haste em movimento. “O goniômetro foi fixado à órtese de modo que o ângulo medido se referisse ao ângulo de onde estaria localizado o punho, com o intuito de calibrar o deslocamento angular da articulação causado pela movimentação da haste” (Ribeiro, 2023). A montagem realizada pelo autor está expressa na Figura 12.

Figura 12 – Configuração experimental com goniômetro acoplado internamente à órtese para mensuração do ângulo articular do punho



Fonte: o autor.

Contudo, optou-se por utilizar neste trabalho, uma nova abordagem considerando ferramentas de visão computacional com ou sem marcadores para a avaliação do deslocamento angular do punho do indivíduo, visto o crescente uso de ferramentas de visão computacional para a avaliação de pacientes com a DP (Güney et al., 2022; Li et al., 2022; Nieto-Hidalgo et al., 2018; Pereira et al., 2016). Além da viabilidade técnica, a opção de substituir o goniômetro por ferramentas de visão computacional, adotada neste trabalho, apresenta uma vantagem adicional importante, ao proporcionar maior conforto ao participante durante o processo de coleta de dados.


Em versões anteriores do protocolo, o uso de um goniômetro acoplado internamente à órtese resultava em contato direto com a pele do indivíduo, o que gerava desconforto e, em alguns casos, risco de lesões ou machucados devido à pressão. A adoção de métodos baseados em visão computacional contribuiu para tornar o processo menos incômodo, favorecendo a adesão ao procedimento e a preservação da integridade física dos voluntários.

4.1.5 Ambiente da coleta de dados

A coleta dos dados foi conduzida em um ambiente controlado e padronizado, com o objetivo de garantir a reprodutibilidade das medidas entre diferentes participantes. Todos os elementos do local de coleta foram organizados previamente, com marcações no solo e na cadeira para assegurar o posicionamento consistente do voluntário em todas as sessões.

O ambiente experimental incluiu uma cadeira fixa, um suporte ajustável para o antebraço avaliado e outro, suporte similar, para o descanso do braço não avaliado, um tripé com um dispositivo de gravação (iPhone 14 Pro Max) posicionado lateralmente em relação ao voluntário, além da órtese instrumentada, da fonte de alimentação e dos materiais de higienização.

Figura 13 – Visão geral do ambiente de coleta de dados



Fonte: o autor.

O voluntário foi inicialmente posicionado em uma cadeira padronizada, disposta sobre uma área demarcada no solo, conforme ilustrado na Figura 13. Antes do acoplamento da órtese, é realizado um protocolo de alongamento passivo da articulação do punho, simulando os movimentos que serão posteriormente executados de forma ativa pelo dispositivo. Essa etapa consiste em 30 segundos de flexão e 30 segundos de extensão do punho, conforme previsto no documento submetido e aprovado pelo Comitê de Ética em Pesquisa (CEP). Durante a coleta, o participante é orientado a não resistir nem reagir voluntariamente à movimentação da órtese, permitindo que o sistema mecânico atue livremente sobre a articulação. A mensuração da rigidez articular foi obtida por meio da força aplicada pelo motor durante os movimentos de

flexão e extensão, partindo-se do pressuposto de que, quanto maior a força exigida para movimentar a articulação, maior foi a rigidez observada.

A Figura 14 apresenta um voluntário já posicionado para o início da coleta de dados, com a órtese instrumentada devidamente acoplada ao antebraço dominante. O participante encontra-se sentado na cadeira padronizada, com o membro avaliado posicionado sobre o suporte ajustável, de forma a garantir o alinhamento adequado para a execução dos movimentos de flexão e extensão do punho.

Figura 14 – Posicionamento do voluntário com a órtese acoplada ao antebraço dominante



Fonte: o autor.

Essa configuração experimental foi planejada para assegurar a estabilidade postural do voluntário, o controle das condições ambientais e a replicabilidade das coletas entre diferentes participantes. A órtese foi acoplada ao antebraço do indivíduo com um posicionamento padronizado a 6 cm do processo estiloide da ulna, respeitando-se as variações anatômicas individuais. Esse critério de posicionamento segue as recomendações de (Costa; Andrade, 2020), com o objetivo de garantir o alinhamento biomecânico adequado e a reprodutibilidade das medições realizadas durante a análise.

4.2 Métodos

4.2.1 Caracterização da Amostra

Este estudo adotou uma amostragem por conveniência, ou seja, com base na facilidade de acesso e não de forma aleatória, composta por dois grupos de participantes: o grupo experimental (GDP), formado por indivíduos com diagnóstico clínico confirmado de Doença

de Parkinson, e o grupo controle (GHC), constituído por voluntários saudáveis, sem histórico de doenças neurológicas. Os participantes com DP foram preferencialmente recrutados em instituições de saúde, como clínicas, hospitais, asilos e instituições de longa permanência na cidade de Uberlândia – MG. Já os indivíduos saudáveis foram selecionados por meio de divulgação pública em redes sociais, fóruns acadêmicos e listas institucionais de e-mails. Os critérios de inclusão e exclusão, bem como o processo de pareamento por idade e sexo entre os grupos, foram mantidos conforme o delineamento metodológico previamente aprovado, e fundamentado em estudos anteriores com protocolos semelhantes (Naranjo et al., 2016; Nielsen; Landauer, 1993; Perez et al., 2016; Virzi, 1992).

Para os critérios de elegibilidade, os voluntários do grupo DP deveriam ter diagnóstico confirmado de doença de Parkinson por médico neurologista ou geriatra. Para ambos os grupos (GDP e HC), os participantes deveriam ter idade entre 40 e 100 anos e possuir capacidade cognitiva para a compreensão das instruções. Adicionalmente, os critérios de exclusão abrangeram indivíduos com histórico de outras doenças neurológicas, cardiorrespiratórias ou musculoesqueléticas. Também foram excluídos voluntários que apresentassem qualquer condição que interferisse diretamente na coleta, como doenças articulares, fraturas, luxações ou condições dolorosas que afetassem o movimento dos membros superiores.

O projeto foi previamente aprovado pelo Comitê de Ética em Pesquisa com Seres Humanos (CEP) da Universidade Federal de Uberlândia, prevendo-se a inclusão de até 25 participantes em cada grupo. No entanto, para esta etapa da pesquisa, considerando as dificuldades encontradas no recrutamento e a viabilidade do cronograma de execução, a amostra utilizada foi composta por 15 indivíduos com DP e 15 voluntários saudáveis, totalizando 30 participantes. A Tabela 3 apresenta a caracterização geral dos participantes deste estudo, distribuídos entre o HC e o DP.

Tabela 3 – Distribuição final dos sujeitos válidos para este estudo

	Grupo DP	Grupo HC	Total
Número de participantes	15	15	30
Sexo (Masculino)	8	8	16
Sexo (Feminino)	7	7	14
Idade (Média ± std) (min-máx)	62,07 ± 5,68 (53-72)	62,00 ± 5,21 (50-69)	-

Fonte: o autor.

Os valores são apresentados como média ± desvio padrão (min-máx)

DP: doença de Parkinson, HC: grupo de controle.


4.2.2 Coleta de dados

Este estudo foi conduzido de acordo com os princípios éticos e aprovado pelo Comitê de Ética em Pesquisa com Seres Humanos da Universidade Federal de Uberlândia (CEP/UFU), sob o número do Certificado de Apresentação de Apreciação Ética (CAAE): 84004924.1.0000.5152. A coleta dos dados foi feita de forma não invasiva, com os devidos cuidados, sem risco à saúde e à integridade física dos voluntários.

A órtese efetua automaticamente os movimentos de flexão e extensão do punho de cada indivíduo. O GDP estava no período “*OFF*” da medicação. Nos indivíduos saudáveis, a órtese foi posicionada na mão dominante, enquanto, nos indivíduos com a DP, foi posicionada na mão mais afetada pela DP. Os pacientes foram orientados e familiarizados com o sistema para não exercerem força voluntária durante os movimentos de flexão e extensão (Sepehri et al., 2007).

A seguir, apresenta-se a Figura 15, que ilustra o movimento de extensão e flexão do punho, realizado ativamente pela órtese utilizada nesta pesquisa. A imagem destaca dois momentos distintos: no item A, observa-se a posição de extensão máxima, enquanto, no item B, é evidenciada a posição de flexão máxima do punho nas configurações de deslocamento da haste da órtese.

Figura 15 – Representação da órtese em movimento automático de extensão (A) e flexão (B) do punho, posicionada nos ângulos máximos de amplitude



Fonte: o autor.

Esses movimentos foram executados automaticamente pela órtese, a partir de parâmetros pré-definidos, com o objetivo de garantir precisão, repetibilidade e segurança durante as sessões experimentais. Além disso, para assegurar o conforto e a correta adaptação às diferenças anatômicas de cada participante, a própria órtese possui um dispositivo de regulagem (item 8) que permite a melhor acomodação na mão do paciente, como ilustrado na

Figura 8. Estipulou-se que o deslocamento padrão seria de -4.500 a 4.500 incrementos (a contar a partir do centro da órtese, com a mão o mais reta possível em relação ao antebraço), podendo esse valor ser alterado caso causasse desconforto aos voluntários. A velocidade de deslocamento foi de 100 incrementos por segundo, com uma aceleração de 0 incrementos por segundo ao quadrado. Tal velocidade foi considerada adequada para a execução do experimento, sem causar incômodo ou dor. A representação evidencia o alcance da amplitude articular proporcionado pelo sistema, fundamental para as análises de desempenho e conforto realizadas no estudo. O escore da MDS-UPDRS para a rigidez utilizada, foi a média dos escores obtidos após avaliação dos indivíduos, por cada avaliador cego, realizada no laboratório NIATS da Universidade Federal de Uberlândia.

Logo após a conclusão das três séries de movimentos induzidos pela órtese, os participantes responderam a dois instrumentos adicionais de avaliação: a Escala Curta de Fluxo (SFSS, do inglês, *Short Flow State Scale*), que foi utilizada para medir a experiência de fluxo do participante, ou seja, o nível de envolvimento e imersão durante a realização da coleta de dados. O questionário é formado por nove afirmações, cada uma representando uma dimensão central do conceito de fluxo, incluindo: equilíbrio entre desafio e habilidade, integração entre ação e pensamento, definição clara de metas, retorno imediato e preciso, concentração plena, sensação de controle, perda de autoconsciência, alteração na percepção do tempo e motivação intrínseca (Jackson; Martin; Eklund, 2008). As respostas são registradas em uma escala de cinco pontos, variando de “discordo totalmente” a “concordo totalmente”, e a Escala de Usabilidade do Sistema (SUS, do inglês, *System Usability Scale*), considerada uma das ferramentas mais confiáveis para avaliação da usabilidade de sistemas, a qual é composta por dez afirmativas, cada uma com cinco opções de resposta, variando de “discordo totalmente” a “concordo totalmente” (BROOKE, 2020).

A medida quantitativa da rigidez foi obtida por meio da órtese ativa. A rigidez foi avaliada pela força necessária para que o motor realizasse os movimentos de flexão e extensão; presume-se que, quanto maior a força necessária para flexão e extensão, maior será a rigidez. De acordo com um estudo prévio (Costa; Andrade, 2020), a estrutura principal da órtese, que é acoplada ao antebraço (Figura 8 - parte 5), foi posicionada a 6 cm do processo estilóide da ulna para todos os voluntários, de acordo com a seguinte sequência:

- Acomodar o participante em uma cadeira, com os dois antebraços apoiados (membro não sendo avaliado sobre uma mesa ou suporte, e membro sendo avaliado sobre um suporte de altura ajustável);

- Realizar o alongamento da articulação do punho: 30 segundos de flexão e 30 segundos de extensão;
- Iniciar a gravação da vista lateral do paciente para a coleta de dados durante a execução da tarefa motora;
- Executar as tarefas motoras, por meio da órtese instrumentada, que consiste em movimentos sequenciados de flexão e extensão de punho, no plano sagital em torno do eixo transversal, executados em 3 séries de 10 repetições com intervalo de 120 segundos entre as séries e movimento iniciado pela extensão de punho.

Após a finalização do movimento passivo promovido pela órtese, o *software* FAULHABER Motion Manager gera automaticamente um arquivo no formato .csv para cada série analisada. Cada arquivo corresponde ao sinal bruto obtido pelo sistema de aquisição da órtese, contendo informações como o tempo de registro, a posição linear da haste do motor e o consumo de corrente elétrica. A Tabela 4 apresenta um exemplo da estrutura desses dados exportados.

Tabela 4 – Modelo dos dados coletados pelo FAULHABER Motion Manager durante análise dinâmica de movimentação

FAULHABER Motion Manager – Dynamic Drive Analysis		
Data		Horário
t[ms]	Y1 [Posição Atual [Inc]]	Y2 [Consumo de corrente pelo motor [mA]]
...	...	...
7095,9	2961	179
7101,9	2999	181
7107,9	3039	183
...	...	...

Fonte: o autor.

t [ms]: tempo em milissegundos;

Y1: posição linear do atuador em incrementos (Inc);

Y2: corrente elétrica consumida pelo motor em miliampères (mA).


A gravação dos movimentos foi realizada utilizando um smartphone iPhone 14 Pro Max, fixado em um tripé posicionado de forma perpendicular à cadeira, de modo a capturar lateralmente a movimentação do membro analisado. O voluntário permaneceu sentado durante as três séries de coleta, e os vídeos foram registrados com uma taxa de 60 quadros por segundo (*fps*) e resolução de 1080p, garantindo boa qualidade para posterior análise da variação angular durante o movimento. A estrutura utilizada para a filmagem pode ser observada na Figura 13,

que apresenta o ambiente completo de coleta de dados. Após a gravação dos vídeos, o material foi inicialmente processado no *software* Adobe After Effects, onde foram inseridos marcadores visuais coloridos sobre o ponto anatômico de interesse (processo estilóide da ulna), com o objetivo de facilitar o rastreamento automático dos segmentos corporais durante a execução do movimento.

Em seguida, os vídeos foram analisados por um algoritmo desenvolvido em Python, que foi empregado para identificar e rastrear marcadores de cor azul nos vídeos dos voluntários, sobrepondo círculos vermelhos sobre eles. O processo inicia com a seleção de uma Região de Interesse (ROI) pelo usuário no primeiro frame do vídeo, delimitando a área onde os marcadores serão buscados. Em seguida, é realizada uma calibração interativa dos parâmetros de cor HSV para a cor azul dos marcadores, permitindo ao usuário ajustar os limites inferior e superior do intervalo de cor.

Após a calibração, o *script* processa o vídeo *frame a frame*. Para cada *frame*, a ROI definida é convertida para o espaço de cor HSV, e uma máscara binária é criada para isolar os pixels que correspondem aos parâmetros HSV calibrados para a cor azul. Contornos são detectados a partir dessa máscara, e os centros de massa de cada contorno (representando os marcadores azuis) são calculados. Finalmente, círculos de cor vermelha pura, representados por (255, 0, 0) no padrão RGB, o que facilita o rastreamento em *softwares* como o Kinovea, são desenhados sobre esses centros no *frame* original, e o vídeo resultante, com os marcadores azuis destacados por círculos vermelhos, é salvo em um novo arquivo. A Figura 16 ilustra o processo de rastreamento dos marcadores em vídeo, desde a seleção da região de interesse até a calibração e identificação final.

Figura 16 – Processo de Rastreamento dos Marcadores em Vídeo




Fonte: o autor.

(A) Seleção da Região de Interesse (ROI) no frame inicial do vídeo, delimitando a área de busca dos marcadores. (B) Interface de calibração HSV, mostrando a imagem original da ROI à esquerda e a máscara binária resultante do ajuste dos parâmetros HSV à direita, destacando os marcadores azuis. (C) Frame final do vídeo processado, exibindo os marcadores azuis identificados com círculos vermelhos puros, (255, 0, 0) no padrão RGB.

Na Figura 167 item (A), observa-se o procedimento de rastreamento automático dos marcadores sobrepostos no vídeo experimental, realizado no *software* Kinovea, com o voluntário devidamente posicionado e a órtese acoplada ao antebraço. Essa configuração viabilizou a extração dos ângulos articulares durante os movimentos de flexão e extensão do punho. No item (B), apresenta-se o gráfico gerado a partir dessa análise, demonstrando a variação angular ao longo do tempo (em milissegundos). A curva evidencia ciclos periódicos de movimento, com amplitudes consistentes entre os picos e os vales, seguidos por uma estabilização final que representa a pausa do dispositivo. A Figura 17 apresenta o vídeo de um voluntário da pesquisa sendo tratado no Kinovea bem como a imagem obtida da variação angular ao longo da coleta de dados para uma série específica.

Figura 17 – Captura e análise dos ângulos articulares do punho utilizando o *software* Kinovea



Fonte: o autor.

(A) Rastreamento automático dos marcadores no vídeo experimental, com o voluntário posicionado e a órtese acoplada ao antebraço.

(B) Gráfico de variação angular gerado com base na análise do vídeo.

O resultado é exportado em formato *.csv*, conforme apresentado na Tabela 5, e visualizado por meio de gráficos como o da Figura 17 (B), permitindo uma análise quantitativa precisa da evolução do movimento ao longo do tempo.

Tabela 5 – Dados temporais e angulares obtidos por rastreamento automático dos marcadores durante o movimento de flexão-extensão do punho

Tempo [ms]	Ângulo [graus]
...	...
3,42008	22,89617064
3,43677	24,06951633
3,45345	25,36960898
...	...

Fonte: o autor.

Com base no modelo de dados apresentados na Tabela 4 e na Tabela 5, provenientes do sinal adquirido pela órtese, foi realizada uma etapa de pré-processamento no *software* MATLAB. A partir desse tratamento, foi aplicado um código específico no MATLAB para extrair um conjunto de características de interesse, relacionadas à rigidez durante o movimento passivo. Essas variáveis derivadas são descritas em detalhes na próxima seção.

4.2.3 Características de interesse

O sinal coletado foi função do tempo, da força fornecida pelo sensor, do ângulo de deslocamento do punho e da corrente consumida pelo servomotor. A visualização inicial dos dados por meio dos gráficos construídos após a coleta, possibilitou o cálculo das características, dadas na Tabela 6, para cada indivíduo.

Para a análise das características, foram utilizadas medidas relacionadas à amplitude do sinal no domínio temporal. Inicialmente, foram extraídas seis características relacionadas à amplitude do sinal da variação de força em relação ao tempo: MAV, PEAK, MAVFD e MAVSD; e duas referentes à dispersão dos dados: STD e RANGE. Dos dados da variação da força em relação ao deslocamento angular, foi calculado o trabalho (W). A partir dos dados da variação da corrente em relação ao tempo, foi calculada a carga (C) (Perera et al., 2019); todas as variáveis são definidas na Tabela 6.

As características extraídas, por exemplo, a partir do cálculo de RMS, PEAK, MAV, MAVFD, MAVSD, estão relacionadas à amplitude do sinal no domínio do tempo, já RANGE e STD são características relacionadas à variabilidade do sinal nesse mesmo domínio (Peres et al., 2021).

Tabela 6 – Descrição e equação para obtenção das características

Característica	Descrição	Equação
PICO	Estima o valor máximo de um vetor	$PICO = \max\{x_i\}_{i=1}^N$
MAV	Estima o valor absoluto médio de um vetor	$MAV = \frac{1}{N} \sum_{i=1}^N x_i $
MAVSD	Estima a média do valor absoluto da segunda diferença	$MAVSD = \frac{1}{N-2} \sum_{i=1}^{N-2} x_{i+2} - x_i $
MAVFD	Estima a média do valor absoluto da primeira diferença	$MAVFD = \frac{1}{N-1} \sum_{i=1}^{N-1} x_{i+1} - x_i $
RANGE	Faixa de amplitude. Diferença entre o valor máximo e mínimo observados.	$RANGE = \max\{x_i\}_{i=1}^n - \min\{x_i\}_{i=1}^n$
STD	Desvio padrão do vetor	$\sigma = STD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$
SLOPE_Extensao	Taxa de força	Medido por meio do coeficiente angular da reta obtida pela regressão linear da variação da força em relação ao deslocamento angular de extensão do punho
SLOPE_Flexao	Taxa de força	Medido por meio do coeficiente angular da reta obtida pela regressão linear da variação da força em relação ao deslocamento angular de flexão do punho
W_Extensao	Trabalho	Área sob a curva da força e o deslocamento angular de extensão do punho.
W_Flexao	Trabalho	Área sob a curva da força e o deslocamento angular de flexão do punho.
C_Extensao	Carga	Área sob a curva da corrente e o tempo durante o movimento de extensão.
C_Flexao	Carga	Área sob a curva da corrente e o tempo durante o movimento de flexão.

Fonte: o autor.

4.2.4 Técnicas para Seleção de Características

Para a classificação das características extraídas após o processo de tratamento dos dados, foi feito o uso de técnicas de seleção de características, como FS (FS, do inglês *feature selection*), CFS (CFS, do inglês *Correlation Feature Selection*), FI (FI, do inglês *Feature Importance*), dentre outras. Após esse processo, as características foram apresentadas aos algoritmos de classificação: RF, SVM, LDA, NB, DT, KNN, dentre outros modelos que serão abordados no estudo, conforme já validados na literatura, em diversas situações e aplicações a problemas biomédicos, e com bons resultados (GIL; JOHNSON, 2009; Karabayir et al., 2020; Karapinar Senturk, 2020; Özseven; Özkorucu, 2023; Rehman et al., 2019; Silva; Ribeiro; Pereira, 2022; Suppa et al., 2022).

A implementação dos classificadores, ou seja, criação, treinamento e validação, foi feita, inicialmente, por meio da linguagem de programação Python, em conjunto com as bibliotecas PyCaret, Scikit-learn e outras bibliotecas.

Nesta etapa, foram utilizadas diversas técnicas para a análise dos modelos de ML, considerando, inicialmente, todas as características extraídas. Em um segundo momento, serão aplicadas técnicas de remoção de características, como observado nos trabalhos propostos por (Karapinar Senturk, 2020; Rehman et al., 2019; Remeseiro; Bolon-Canedo, 2019; Suppa et al., 2022), para observar o comportamento dos modelos, bem como uma possível variação na dimensão do conjunto de dados destinados ao treinamento e teste e no número de *folds* utilizados no processo de validação cruzada.

A aplicação da técnica de validação cruzada, da técnica de FS e o ajuste de hiperparâmetros visam mitigar o risco de *overfitting*, ou seja, evitar que os dados se ajustem excessivamente ao conjunto destinado ao treinamento do modelo, o que faz com que estes percam a capacidade de generalização.


4.2.5 Apresentação dos dados aos modelos de ML

O conjunto de dados utilizado neste estudo foi submetido inicialmente a um processo de pré-processamento com auxílio da biblioteca Pandas, que possibilitou sua organização e adequação para aplicação na função *setup* da biblioteca PyCaret. Esse procedimento permitiu estruturar uma *pipeline* de preparação dos dados para os modelos de classificação, automatizando etapas como tratamento de variáveis, padronização e geração de métricas experimentais (Moez Ali, 2020; Silva et al., 2025; Tolios, 2022). A Figura 18 ilustra o fluxo de

trabalho adotado para a modelagem supervisionada no contexto de auxílio ao diagnóstico da DP.

Como observado na Figura 18, o conjunto de dados é composto por informações de 30 participantes, totalizando 90 registros, e passou inicialmente por pré-processamento com a biblioteca Pandas, preparando os dados para aplicação por meio da função `setup` do PyCaret. O conjunto de dados foi importado no formato .xlsx, contendo 45 registros de voluntários com DP e 45 de voluntários do HC. Ao executar a função `setup`, obteve-se uma tabela com informações relevantes, acompanhada de explicações detalhadas sobre suas configurações e parâmetros (Silva et al., 2025; Tolios, 2022).

Figura 18 – Fluxo de trabalho para a modelagem supervisionada com PyCaret.



Fonte: o autor.

A avaliação do desempenho dos algoritmos foi realizada por meio da validação cruzada com $k = 5$ folds, metodologia amplamente descrita na literatura (Karabayir et al., 2020; Karapinar Senturk, 2020; Rehman et al., 2019). Esse processo assegura maior confiabilidade

aos resultados, uma vez que cada partição do conjunto de dados é utilizada de forma alternada em treino e teste, evitando que os modelos se ajustem excessivamente a um único subconjunto.

A performance dos classificadores é expressa em termos de acurácia média e desvio padrão, parâmetros que fornecem uma visão geral da consistência dos resultados. Para a etapa de otimização, os dados foram particionados em conjuntos de treinamento e teste em proporções equivalentes às práticas recomendadas, assegurando a avaliação da capacidade de generalização. Essa divisão é especialmente relevante em cenários de base reduzida, pois contribui para minimizar distorções e ampliar a robustez dos resultados (Tougui; Jilbab; Mhamdi, 2022; Vabalas et al., 2019).

Adicionalmente, foi implementada a técnica de seleção de características por correlação CFS, a qual se justifica pela necessidade de mitigar problemas associados ao uso de variáveis irrelevantes, redundantes ou altamente correlacionadas, visando aprimorar a robustez dos modelos e conter potenciais efeitos de *overfitting*. Tais métodos não apenas favorecem o ajuste fino dos parâmetros, mas também fortalecem a resiliência das soluções obtidas, em consonância com práticas consolidadas em modelagem preditiva (Bruce; Bruce; Gedeck, 2020).

4.2.6 Proposta Metodológica do Modelo Matemático para Predição da Rigidez

O desenvolvimento de um modelo matemático para a predição quantitativa da rigidez, com base no Item 3.3 da escala MDS-UPDRS, seguiu uma metodologia sistemática. A avaliação do desempenho dos modelos foi desenhada sob uma ótica dupla e complementar.

- i. **Análise de Regressão (Precisão Matemática):** focada em quantificar o poder explicativo e o erro de previsão do modelo. As métricas selecionadas para esta análise foram o R-quadrado Ajustado (R_{adj}), para medir a proporção da variância explicada com penalidade por complexidade, e a Raiz do Erro Quadrático Médio (RMSE), para medir a magnitude média do erro de previsão na escala da MDS-UPDRS de modo similar ao proposto por Perera *et al.* (2019);
- ii. **Análise de Classificação (Relevância Clínica):** focada em traduzir o desempenho do modelo para um contexto prático e clinicamente interpretável. Esta abordagem inovadora envolve o arredondamento das previsões contínuas do modelo para o número inteiro mais próximo, permitindo a avaliação com métricas de classificação. Foram definidas a Acurácia Exata e a Acurácia que chamamos neste estudo de "Ampliada" (a porcentagem de previsões que acertam o *score* exato ou erram por no máximo ± 1

ponto), sendo esta última de particular interesse para determinar a confiabilidade do dispositivo em um cenário real.

Como ponto de partida, foi desenvolvido um modelo de base utilizando a Regressão Linear Múltipla com o conjunto completo de 12 variáveis preditoras. O objetivo foi estabelecer um benchmark de desempenho e diagnosticar limitações dos dados, como a multicolinearidade, através do Fator de Inflação de Variância (VIF).

Paralelamente, foram investigados modelos não lineares mais complexos, como Random Forest Regressor e Support Vector Regressor (SVR), para verificar se poderiam capturar relações não explícitas nos dados. Contudo, em um cenário com dados limitados ($N=45$), esses modelos apresentaram R^2 negativo na validação cruzada, indicando forte *overfitting* e a incapacidade de generalizar. Este resultado reforçou a decisão de que um modelo de regressão linear, mais robusto e interpretável, seria a abordagem mais adequada, desde que otimizado com uma estratégia de seleção de características mais sofisticada.

Para superar as limitações identificadas no modelo de base e buscar uma solução mais robusta, uma estratégia de otimização foi implementada, inspirada na literatura similar à proposta de Perera *et al.* (2019). Esta abordagem consistiu em duas etapas: primeiro, uma Engenharia de Features, onde o conjunto de 12 preditores foi expandido para 78 características candidatas, incluindo todos os termos de interação de segunda ordem; e segundo uma Seleção de Características *Stepwise*.

Para a seleção, foi utilizada a técnica de Seleção Progressiva de Variáveis (*Forward Stepwise Selection*). Este método iterativo inicia com um modelo nulo, contendo apenas o intercepto, e, a cada passo, adiciona a característica original ou de interação, que apresenta o menor p – *valor*, desde que este seja inferior ao nível de significância adotado ($\alpha = 0,05$). O processo é interrompido quando nenhuma variável restante atende a este critério, garantindo um modelo final parcimonioso, interpretável e contendo apenas os preditores com a mais forte evidência estatística de associação com a rigidez.

Finalmente, para a análise de relevância clínica, as previsões contínuas geradas pelos modelos foram arredondadas para o valor inteiro mais próximo. A performance foi então medida pela Acurácia Exata e, de maior interesse prático, pela Acurácia "Ampliada", que considera como acerto as previsões exatas ou com desvio máximo de ± 1 ponto.

Essa abordagem garante que o modelo final contenha apenas os preditores com a maior evidência estatística de associação com a variável de resposta, resultando em um modelo final robusto e de fácil interpretação.

4.2.7 Avaliação dos voluntários segunda a escala MDS-UPDRS

A avaliação da parte III da escala MDS-UPDRS foi realizada por meio de um formulário detalhado para análise dessa escala. Para garantir a confiabilidade e objetividade das avaliações, o procedimento metodológico adotado neste estudo seguiu a prática de pontuação por dois avaliadores cegos e independentes.

A utilização de dois avaliadores cegos e independentes é um procedimento fundamental para assegurar a confiabilidade e objetividade na pontuação de escalas neurológicas, como a MDS-UPDRS (Marsili et al., 2023; Noyce et al., 2017). Os estudos apresentados a seguir demonstram a implementação dessa prática em suas metodologias. Por exemplo, Marsili *et al.* (2023) utilizaram dois avaliadores treinados em distúrbios do movimento, que estavam cegos ao diagnóstico, para pontuar retrospectivamente as gravações em vídeo da Parte III da MDS-UPDRS. Da mesma forma, Noyce et al. (2016) ressaltam que as gravações de exames neurológicos foram pontuadas de forma cega e independente por dois especialistas em distúrbios do movimento, sem que esses tivessem informações adicionais sobre os participantes. Esse cegamento e independência são cruciais para reduzir o viés do observador e garantir que as avaliações reflitam a condição do paciente de forma imparcial.

Para otimizar a precisão, o processo com múltiplos avaliadores tipicamente inclui etapas claras para a resolução de discrepâncias. No estudo de Noyce *et al.* (2016), se a diferença entre as pontuações individuais dos avaliadores fosse inferior a 5 pontos na MDS-UPDRS, as pontuações eram calculadas como média, indicando alta concordância. No entanto, se houvesse uma disparidade significativa (igual ou superior a 5 pontos), os avaliadores eram instruídos a pontuar novamente de forma independente. Esta reavaliação é um passo vital para minimizar erros e confirmar a acurácia. Caso a diferença persistisse após a segunda rodada de avaliações, os avaliadores se reuniam para pontuar em conjunto e chegar a um consenso.

No presente estudo, o procedimento de pontuação adotado seguiu a metodologia amplamente reconhecida e utilizada em pesquisas anteriores, envolvendo a avaliação cega e independente da MDS-UPDRS. Especificamente, as pontuações foram atribuídas por dois avaliadores independentes, conforme já mencionado na Seção 4.2.2 deste trabalho, com critérios claros para a resolução de discrepâncias: a média das pontuações para diferenças menores que 5 pontos e reavaliações independentes seguidas de consenso para diferenças iguais ou superiores a 5 pontos, conforme detalhado por Noyce *et al.* (2016).

Neste estudo, foi adotada a mesma estratégia apresentada por Noyce *et al.* (2016) e Marsili *et al.* (2023), com o objetivo de obter uma medida quantitativa abrangente da severidade

dos sintomas motores. O somatório das pontuações atribuídas a todos os itens que compõem esta parte da escala é comumente empregado, resultando em um escore total que reflete o estado do paciente (Marsili et al., 2023; Noyce et al., 2017). Ademais, dado o enfoque central da pesquisa na quantificação da rigidez, que será considerada e correlacionada, separadamente, aos dados objetivos da órtese de punho desenvolvida, conforme sua importância para os objetivos do trabalho.

4.2.8 Fluxograma das etapas de coleta, organização e modelagem do trabalho

O fluxo metodológico deste estudo foi dividido em etapas, tais como: definição do protocolo e coleta de dados, filtragem dos sinais, cálculo das características, análise estatística, criação de um modelo matemático e teste do modelo com diversos algoritmos de ML. As etapas de realização deste estudo estão representadas na Figura 19, de modo que a partir do fluxograma se possa visualizar o passo a passo utilizado para alcançar o objetivo geral anteriormente apresentado.

Figura 19 – Fluxograma ilustrando todo o desenvolvimento da pesquisa



Fonte: o autor.

Na primeira etapa, realizou-se a coleta de dados por meio da aplicação das escalas SFSS, SUS e MDS-UPDRS, associada à aquisição dos sinais gerados pela órtese e à filmagem dos movimentos de flexão e de extensão do punho. Nesta fase, os vídeos foram ajustados e

sincronizados com os sinais da órtese por meio de técnicas de filtragem, com um filtro passa-faixa entre 1 Hz e 16 Hz para remover artefatos de baixa e alta frequência (Jeon et al., 2017).

A segunda etapa contemplou a organização e a geração dos conjuntos de dados, envolvendo tanto os resultados obtidos nas escalas aplicadas quanto as características extraídas do processamento dos sinais da órtese e das filmagens. Esses dados foram submetidos a análises estatísticas descritivas e inferenciais, com o objetivo de identificar padrões relevantes, diferenças significativas entre os grupos de estudo (DP e HC) e possíveis correlações entre os escores das escalas e as características biomecânicas derivadas dos sinais. Além disso, as informações oriundas da escala SUS, voltada à avaliação da usabilidade, e da escala curta de fluxo SFSS forneceram subsídios importantes para analisar a experiência dos participantes com o sistema, permitindo não apenas validar o protocolo experimental, mas também identificar aspectos passíveis de aprimoramento em estudos futuros, sendo esta etapa fundamental para assegurar a consistência dos dados coletados e estabelecer uma base sólida para a modelagem desenvolvida nas etapas subsequentes.

Por fim, a terceira etapa foi dividida em duas frentes complementares, diretamente relacionadas às hipóteses levantadas na fase inicial do projeto.

- (i) a análise de modelos de aprendizado de máquina utilizando a biblioteca PyCaret, com o objetivo de verificar a capacidade de classificação entre indivíduos com DP e HC, buscando alcançar níveis de acurácia comparáveis aos reportados na literatura (Rehman et al., 2019; Silva et al., 2025a; Tougui; Jilbab; Mhamdi, 2022) em estudos relacionados a biomarcadores para a DP;
- (ii) o desenvolvimento de um modelo matemático voltado à quantificação da rigidez, fundamentado nas 12 características extraídas dos sinais da órtese e dos vídeos, em associação com os resultados das avaliações clínicas da escala MDS-UPDRS, tanto no escore global do item III (eixo motor) quanto nos itens específicos relacionados à rigidez (3.3a–e).

A Figura 19 sintetiza as etapas do projeto e seus principais objetivos, servindo como guia visual para compreender a estrutura metodológica adotada. Os resultados obtidos a partir desse processo, organizados de acordo com cada etapa, serão apresentados e discutidos na próxima seção.


5. RESULTADOS E DISCUSSÃO

Neste capítulo, são apresentados e discutidos os principais resultados obtidos a partir dos dados registrados pela órtese desenvolvida e das filmagens realizadas durante os movimentos. As informações extraídas permitiram analisar a variação angular do punho e fornecer subsídios objetivos para a avaliação da rigidez muscular. Inicialmente, são descritos os procedimentos de aquisição e organização dos dados, seguidos pela apresentação das análises estatísticas e gráficas realizadas. Por fim, os achados são interpretados à luz da literatura e das potencialidades da abordagem adotada.

5.1 Caracterização da Amostra

A distribuição etária dos grupos HC e DP foi inicialmente inspecionada por meio de histogramas com curvas de densidade, conforme ilustrado na Figura 20. Essa representação gráfica permite observar uma considerável sobreposição entre as faixas etárias dos grupos, o que reforça a adequação do critério de pareamento por idade adotado na seleção da amostra.


Figura 20 – Histogramas sobrepostos representando a distribuição das idades dos participantes dos grupos controle e com Doença de Parkinson.



Fonte: o autor.

Observa-se, pelos *boxplots* apresentados na Figura 21, que a mediana e a dispersão das idades são bastante similares entre os grupos, com ausência de *outliers* extremos.

Figura 21 – Boxplots das idades dos participantes nos grupos controle e com Doença de Parkinson.



Fonte: o autor.

As distribuições são semelhantes entre os grupos, sem presença de outliers extremos, reforçando a comparabilidade quanto à variável idade.

Para confirmar a comparabilidade etária entre os grupos HC e DP, foram aplicados testes estatísticos apropriados, em conformidade com os pressupostos metodológicos. Inicialmente, utilizou-se o teste de Shapiro-Wilk para avaliar a normalidade da distribuição da variável idade em cada grupo. Este teste é considerado um dos mais robustos para amostras pequenas e médias e tem como hipótese nula (H_0) a suposição de que os dados provêm de uma distribuição normal (Shapiro; Wilk, 1965). Em ambos os grupos, os resultados indicaram, respectivamente, $p - valor = 0,2174$ e $p - valor = 0,6898$ evidenciando que os p-valores são superiores ao nível de significância adotado ($\alpha = 0,05$), sugerindo distribuição normal para a variável idade.

Na sequência, foi aplicado o teste de Levene (Vieira, 2006) para verificar a homogeneidade das variâncias entre os grupos, requisito essencial para a aplicação do teste t tradicional. A hipótese nula (H_0), neste caso, assume a igualdade de variâncias. O resultado obtido $p - valor = 0,6695$ foi superior ao nível de significância de $\alpha = 0,05$, indicando que o teste falhou em rejeitar a hipótese nula. Desta forma, não havendo evidência de heterogeneidade das variâncias, optou-se pelo teste *t de Student* para comparação entre médias de grupos independentes (Student, 1908).

O teste de *t de Student* tem como objetivo verificar a existência de diferença estatisticamente significativa entre as médias das idades dos dois grupos. Uma vez que os testes de pressupostos não indicaram violação da normalidade ou da homogeneidade, aplicou-se o teste de variâncias iguais. O resultado do teste foi muito superior ao limiar de significância

adotado; portanto, não foi encontrada diferença estatisticamente significativa entre as idades dos grupos, o que sustenta a comparabilidade entre os grupos neste estudo.

Deste modo, a interpretação conjunta desses testes confirma que os grupos são comparáveis quanto à idade, o que valida o pareamento etário entre os participantes. A subseção a seguir apresentará os resultados dos modelos de ML aplicados à classificação dos participantes com base nas métricas extraídas da órtese, bem como a avaliação do modelo matemático proposto para a quantificação da rigidez do punho.

5.2 Resultados da análise estatística para o conjunto de características

Compararam-se voluntários com DP e HC, que geraram $n = 45$ registros em cada grupo, para métricas biomecânicas extraídas da órtese de punho e de ferramentas de visão computacional durante movimentos de flexão e extensão. A normalidade foi avaliada separadamente por grupo com o teste de Shapiro Wilk ($\alpha = 0,05$). Variáveis que apresentaram normalidade em ambos os grupos foram comparadas com o teste t de Welch (homocedasticidade verificada por Levene). As variáveis não normais foram comparadas com o teste de Mann–Whitney. Reportamos p-valores e intervalos de confiança de 95% (IC95%) das diferenças entre grupos.

De forma geral, 3 das 12 variáveis apresentaram diferenças estatisticamente significativas entre DP e HC, ou seja, com $p - \text{valor} \leq 0,05$. As discrepâncias concentraram-se principalmente em domínios ligados à amplitude e à velocidade do movimento, evidenciados por um valor maior da taxa de força, do trabalho e da carga, sugerindo um maior consumo de corrente e consequentemente, de maior força para a realização do movimento de flexão do punho.

Clinicamente, os resultados indicam que os participantes com PD exibem redução da amplitude em tarefas de flexão e extensão, achado compatível com bradicinesia e rigidez. Essa coerência fisiopatológica reforça o potencial das métricas instrumentais como marcadores quantitativos do comprometimento motor, úteis para o monitoramento e a avaliação de intervenções. A Tabela 7 apresenta, para cada variável, o teste aplicado, o valor de p e o IC95% da diferença $\Delta(\text{DP} - \text{HC})$, representando a diferença entre as médias ou medianas, de acordo com a natureza (paramétrica ou não paramétrica) do teste utilizado.

A Figura 22 apresenta o gráfico de árvore (*forest plot*) com os efeitos padronizados ($z = \Delta/\text{SE}$) e seus respectivos IC95% para cada variável. Os pontos foram diferenciados conforme o teste estatístico utilizado (t-teste de Welch ou Mann–Whitney U).


Tabela 7 – Comparação DP vs. HC por variável: teste aplicado, p-valor e IC95% da diferença Δ (DP – HC)

Variável	Teste	p-valor	Δ (DP–HC)	IC 95% Δ low	IC 95% Δ high
CARGA_Flexao	Mann-Whitney U	0,0028	0,001009447	0,000390192	0,001742536
TRABALHO_Flexao	Welch t-test	0,0057	-0,283238147	-0,481682239	-0,084794054
SLOPE_Flexao	Mann-Whitney U	0,0151	-0,014858176	-0,027928081	-0,002725394
TRABALHO_Extensao	Welch t-test	0,0811	-0,126173074	-0,268279469	0,015933321
SLOPE_Extensao	Mann-Whitney U	0,1726	-0,013298528	-0,034383808	0,006004780
STD	Mann-Whitney U	0,2831	0,113783941	-0,087498444	0,321870574
CARGA_Extensao	Mann-Whitney U	0,2979	0,000716853	-0,000563366	0,002166402
PICO	Mann-Whitney U	0,3209	0,110863058	-0,137787469	0,379906509
MAV	Welch t-test	0,6663	-0,003082824	-0,017245324	0,011079677
MAVSD	Mann-Whitney U	0,6925	-0,001361116	-0,007036233	0,006970973
MAVFD	Mann-Whitney U	0,6985	-0,000686797	-0,003520727	0,003470062
RANGE	Mann-Whitney U	0,6985	-0,043419716	-0,245422870	0,189413363

Fonte: o autor.

Valores à esquerda da linha de referência (zero) na Figura 22 indicam que o grupo DP apresentou valores menores em comparação ao grupo HC, enquanto valores à direita indicam maiores.

Figura 22 – Forest plot dos efeitos padronizados ($z = \Delta/SE$) com intervalos de confiança de 95% para cada variável analisada.



Fonte: o autor.

Δ : Welch = diferença de MÉDIAS; Mann–Whitney = diferença de MEDIANAS.

SE: Erro Padrão da estimativa (*Standard Error*)

Asterisco: $p \leq 0,05$.

As barras horizontais representam os intervalos de confiança de 95%, e as variáveis assinaladas com asterisco indicam diferenças estatisticamente significativas ($p \leq 0,05$). Além da apresentação dos resultados brutos (Δ e IC95%), optou-se por calcular e representar os efeitos padronizados, obtidos pela razão entre a diferença observada e o seu erro padrão ($z = \Delta/SE$). O erro padrão (SE) foi estimado a partir da amplitude dos intervalos de confiança de 95%, considerando a relação $IC95\% = \Delta \pm 1,96 * SE$. Essa padronização gera uma escala adimensional, permitindo a comparação direta entre variáveis com diferentes unidades de medida e evidenciando a relevância estatística mesmo quando os valores absolutos de Δ eram numericamente pequenos.

Observa-se que 3 das 12 variáveis avaliadas apresentaram diferenças significativas entre os grupos, enquanto nas demais o IC95% incluiu o valor zero, indicando ausência de diferença estatística ao nível adotado.


5.3 Resultado para os modelos de classificação usando ML

O conjunto de dados utilizado neste estudo é composto por 90 registros, distribuídos de forma balanceada entre dois grupos: DP e HC. Para cada registro, foram extraídas 12 características derivadas da análise dos sinais obtidos durante os movimentos de flexão e extensão do punho, capturados por meio da órtese ativa. Além dessas variáveis preditoras, o conjunto inclui a variável alvo, representando o grupo ao qual cada voluntário pertence, codificada de forma binária: 0 para HC e 1 para DP.

Após a análise dos dados por meio da matriz de correlação (*heat map*), que ilustra de forma visual as inter-relações entre as variáveis extraídas dos movimentos de flexão e extensão do punho, conforme apresentado na Figura 23, foi possível identificar os padrões de correlação existentes entre as 12 características analisadas.

Essa abordagem permite compreender a intensidade e a direção das associações entre as variáveis, servindo como etapa preliminar essencial para a aplicação de métodos de seleção de características, como o CFS, para a mitigação de redundâncias nos modelos de ML.

Figura 23 – Heat Map mostrando a correlação entre as 12 características antes da aplicação do método de seleção de características.



Fonte: o autor.

5.3.1 Resultado dos modelos de ML aplicados a todas as características

Os resultados apresentados na Tabela 9 foram obtidos a partir da implementação dos algoritmos utilizando a biblioteca PyCaret, considerando os parâmetros definidos como padrão. Para cada modelo, a acurácia média foi calculada em termos percentuais, adotando as condições experimentais apresentadas na Tabela 8.

Tabela 8 – Parâmetros do pipeline para implementação dos modelos para todas as variáveis

Modelos	Parâmetros	Valores
19 modelos	Dados de treinamento	75%
	Estratégia de <i>folds</i>	Kfold
	Número de <i>folds</i>	5
	Normalização	z-score
	Embaralhamento dos <i>folds</i>	Verdadeiro
	Semente	1245

Fonte: o autor.

Os demais parâmetros da função setup foram mantidos conforme a configuração padrão. Adicionalmente, foi estabelecida uma semente padrão para garantir a replicabilidade do experimento com uma semente e a consistência dos resultados obtidos.

Tabela 9 – Análise de desempenho dos 19 modelos aplicados aos dados de treinamento considerando todas as variáveis

Modelos	Dados de Treinamento (todas as variáveis)					
	Valor médio da Acurácia, Sensibilidade, Precisão, F1-score em (%), AUC ([0,1]) e MCC ([-1,1])					
	Accuracy	AUC	Recall	Prec.	F1	MCC
QDA	0,9130	0,8939	1,0000	0,8571	0,9231	0,8374
CATBOOST	0,7826	0,8636	0,6667	0,8889	0,7619	0,5893
LDA	0,7826	0,7879	0,6667	0,8889	0,7619	0,5893
RBFSVM	0,7826	0,8333	0,6667	0,8889	0,7619	0,5893
GPC	0,7826	0,7879	0,5833	1,0000	0,7368	0,6333
NB	0,7826	0,7803	0,5833	1,0000	0,7368	0,6333
ET	0,7391	0,8447	0,5833	0,8750	0,7000	0,5165
LIGHTGBM	0,7391	0,8030	0,5833	0,8750	0,7000	0,5165
RF	0,7391	0,8712	0,5833	0,8750	0,7000	0,5165
ADA	0,6957	0,7045	0,5833	0,7778	0,6667	0,4110
KNN	0,6957	0,7576	0,5833	0,7778	0,6667	0,4110
MLP	0,6957	0,8788	0,5833	0,7778	0,6667	0,4110
XGBOOST	0,6957	0,8030	0,5833	0,7778	0,6667	0,4110
GBC	0,6522	0,7652	0,5833	0,7000	0,6364	0,3130
RIDGE	0,6522	0,6553	0,5833	0,7000	0,6364	0,3130
DT	0,6522	0,6591	0,5000	0,7500	0,6000	0,3337
LR	0,6522	0,6894	0,5000	0,7500	0,6000	0,3337
SVM	0,6087	0,6098	0,5833	0,6364	0,6087	0,2197
DUMMY	0,4783	0,5000	0,0000	0,0000	0,0000	0,0000

Fonte: o autor.

Após a análise inicial dos 19 modelos, conforme apresentados na Tabela 9, observa-se que os modelos QDA, CATBOOST, LDA, RBFSVM, GBC e NB foram os seis modelos de melhor desempenho nos dados de teste, porém, sem a otimização dos hiperparâmetros de cada modelo. Na sequência, foi realizado um processo sistemático de otimização de hiperparâmetros aplicável a todos os algoritmos avaliados, sem distinção, utilizando a função *tune_model* do PyCaret, ajustando de forma padronizada e mantendo uma abordagem uniforme para todos os classificadores considerados. Deste modo, com o intuito de refinar o desempenho, procedeu-se à otimização sistemática de hiperparâmetros para todos os classificadores empregando a seguinte pipeline, representada na Tabela 10.

Tabela 10 – Parâmetros do pipeline para otimização dos modelos usando função `tune_model` do PyCaret.

Modelos	Parâmetros	Valores
19 modelos	Número de iterações	50
	Métrica de otimização	F1
	Escolher melhor modelo	True

Fonte: o autor.

O número de 50 iterações foi aplicado a cada modelo ($n_iter = 50$) associado com a função objetivo que neste estudo foi definida como F1 ($optimize = 'F1'$), por equilibrar precisão e sensibilidade (Rehman et al., 2019; Silva et al., 2025a), e o parâmetro $choose_better = True$ assegurou que o modelo ajustado apenas substituísse o baseline quando apresentasse ganho na métrica, preservando a comparabilidade e mitigando riscos de degradação. A Tabela 11 apresenta os 7 melhores modelos após a aplicação da função `tune_model`, com os parâmetros da pipeline de otimização.

Após a otimização, todos os modelos foram aplicados aos dados de teste por meio da função `predict_model` do PyCaret, cujos resultados são apresentados na Tabela 11, incluindo as principais métricas de desempenho obtidas para cada classificador. Essa etapa final permitiu consolidar a avaliação dos modelos e identificar aqueles com maior potencial preditivo no contexto deste estudo.

Tabela 11 – Análise de desempenho dos 7 melhores modelos, após o processo de otimização, aplicados aos dados de teste considerando todas as variáveis disponíveis.


Modelos	Dados de Teste (todas as variáveis)					
	Valor médio da Acurácia, Sensibilidade, Precisão, F1-score em (%), AUC ([0,1]) e MCC ([-1,1])					
	Accuracy	AUC	Recall	Prec.	F1	MCC
QDA	0,9130	0,8939	1,0000	0,8571	0,9231	0,8374
MLP	0,8696	0,8939	0,7500	1,0000	0,8571	0,7676
KNN	0,8261	0,8182	0,6667	1,0000	0,8000	0,6992
ADA	0,7826	0,7955	0,6667	0,8889	0,7619	0,5893
CATBOOST	0,7826	0,8636	0,6667	0,8889	0,7619	0,5893
LDA	0,7826	0,7879	0,6667	0,8889	0,7619	0,5893
RBFSVM	0,7826	0,8561	0,6667	0,8889	0,7619	0,5893

Fonte: o autor.

Toda a busca foi conduzida com configuração uniforme entre algoritmos e em modo silencioso ($verbose = False$), garantindo isonomia metodológica na avaliação após o

treinamento. A Figura 24 traz um comparativo contendo os sete modelos com melhor desempenho, apresentando os valores médios de acurácia e a variação em percentual antes e após o processo de otimização.

Figura 24 – Comparação da acurácia média (%) antes e depois da otimização para os sete melhores modelos de classificação considerando todas as características



Fonte: o autor.

Após a otimização, três modelos apresentaram melhoria na acurácia média. O MLP foi o que mais se destacou, com um incremento de 25%, passando de 69,57% para 86,96%. Em seguida, o KNN evoluiu de 69,57% para 82,61%, resultando em um ganho de 18,7%, enquanto o AdaBoost aumentou de 69,57% para 78,26%, representando uma melhora de 12,4%. Os demais modelos (QDA, CatBoost, LDA e RBF-SVM) não apresentaram variação em seus desempenhos. Considerando o conjunto dos sete modelos, a acurácia média global passou de 76,40% para 82,23%, correspondendo a um aumento médio de +5,83%, o que evidencia o impacto positivo da etapa de otimização, sobretudo para os classificadores mais sensíveis à escolha de hiperparâmetros.

5.3.2 Resultado dos modelos de ML aplicados ao conjunto de características após a aplicação da técnica de CFS

Segundo Remeseiro e Bolon-Canedo (2019), a seleção de características tem se mostrado uma ferramenta de pré-processamento eficiente para problemas de machine learning. Neste estudo, foi aplicado apenas um método de FS com o intuito de remover variáveis altamente correlacionadas, motivada pelos resultados relatados na literatura (Rehman et al.,

2019; Remeseiro; Bolon-Canedo, 2019; Suppa et al., 2022), quanto ao aumento para os valores de acurácia, como observado em (Karapinar Senturk, 2020; Silva et al., 2025), obtidos após o uso de técnicas de remoção de features e pelo resultado observado na Figura 23.

O método empregado foi o CFS, conforme definido em (Rehman et al., 2019; Silva et al., 2025b), sendo utilizado para selecionar características altamente correlacionadas do sinal obtido, empregando um limiar para o coeficiente de correlação $r \geq 0,96$. Os valores de correlação das variáveis removidas variaram entre 0,96 e 0,99, confirmando o alto nível de correlação.

Ao todo, foram eliminadas duas variáveis, e o conjunto final de características, incluindo as selecionadas e as excluídas, está detalhado na Tabela 12, com exceção da variável alvo para os modelos, que é a variável Grupo.

Tabela 12 – Conjunto de variáveis removidas e selecionadas para serem aplicadas aos modelos de ML após o método de seleção de variáveis CFS.

Método	Características Removidas	Características Selecionadas
CFS	MAVFD, PICO	MAV, MAVSD, RANGE, STD, SLOPE_Extensao, SLOPE_Flexao, TRABALHO_Extensao, TRABALHO_Flexao, CARGA_Extensao, CARGA_Flexao
Número	2	10

Fonte: o autor.

Para seguir o fluxo representado na Figura 18, procedeu-se à análise dos modelos aplicados ao conjunto de características, incorporando uma técnica de seleção de características em que o objetivo foi avaliar o comportamento dos classificadores e, ao mesmo tempo, mitigar riscos de *overfitting* aos dados.

Adotando-se as seguintes condições experimentais apresentadas na Tabela 8 acrescidas dos elementos para seleção de características referentes à técnica de CFS temos os parâmetros apresentados na Tabela 13.

Tabela 13 – Parâmetros do pipeline para implementação dos modelos para a aplicação de técnica para seleção de características

Modelos	Parâmetros	Valores
19 modelos	Dados de treinamento	75%
	Estratégia de <i>folds</i>	Kfold
	Número de <i>folds</i>	5
	Normalização	z-score
	Embaralhamento dos <i>folds</i>	Verdadeiro
	Semente	1245
	Remover multicolinearidade	Verdadeiro
	Escore do multicolinearidade	0,95

Fonte: o autor.

A partir dos parâmetros apresentados na Tabela 13 obtém-se os dados apresentados na Tabela 14 com a aplicação da técnica de remoção de características CFS.

Tabela 14 – Análise de desempenho dos 19 modelos ao serem aplicados aos dados de treinamento considerando a técnica de remoção de características.

Modelos	Dados de Treinamento (seleção de variáveis)					
	Valor médio da Acurácia, Sensibilidade, Precisão, F1-score em (%), AUC ([0,1]) e MCC ([-1,1])					
	Accuracy	AUC	Recall	Prec.	F1	MCC
ET	0,8696	0,8902	0,7500	1,0000	0,8571	0,7676
QDA	0,8261	0,8561	0,8333	0,8333	0,8333	0,6515
MLP	0,8261	0,8864	0,7500	0,9000	0,8182	0,6641
GPC	0,7826	0,7955	0,5833	1,0000	0,7368	0,6333
NB	0,7826	0,7955	0,5833	1,0000	0,7368	0,6333
ADA	0,7391	0,7955	0,6667	0,8000	0,7273	0,4886
GBC	0,7391	0,7576	0,6667	0,8000	0,7273	0,4886
RBFSVM	0,7391	0,8030	0,5833	0,8750	0,7000	0,5165
LIGHTGBM	0,6957	0,8258	0,5833	0,7778	0,6667	0,4110
RF	0,6957	0,8561	0,5833	0,7778	0,6667	0,4110
XGBOOST	0,6957	0,8030	0,5833	0,7778	0,6667	0,4110
KNN	0,6957	0,8144	0,4167	1,0000	0,5882	0,5046
DT	0,6522	0,6553	0,5833	0,7000	0,6364	0,3130
LR	0,6522	0,6136	0,5000	0,7500	0,6000	0,3337
RIDGE	0,6522	0,6591	0,5000	0,7500	0,6000	0,3337
SVM	0,6087	0,6098	0,5833	0,6364	0,6087	0,2197
LDA	0,6087	0,5985	0,5000	0,6667	0,5714	0,2326
DUMMY	0,4783	0,5000	0,0000	0,0000	0,0000	0,0000

Fonte: o autor.

Após a análise inicial dos 19 modelos conforme apresentado na Tabela 14, observa-se que os modelos ET, QDA, MLP, GPC, NB e ADA foram os de melhor desempenho sobre os dados de treinamento, porém, sem a otimização de hiperparâmetros de cada modelo.

Na sequência, foi realizado um processo sistemático de otimização de hiperparâmetros aplicáveis a todos os algoritmos avaliados para manter a padronização metodológica, aplicada na análise realizada quando considera-se todas as características, e com o intuito de refinar o desempenho dos modelos empregou-se a busca considerando a pipeline já representada na Tabela 10 com uma única diferença no número de iterações que neste caso foi considerado um $n = 200$. Com a aplicação desta pipeline é possível selecionar os 7 modelos de melhor desempenho sobre os dados de teste após a aplicação da técnica de CFS.

Tabela 15 – Análise de desempenho dos 7 melhores modelos aplicados aos dados de teste considerando após a aplicação da técnica de CFS.


Modelo	Dados de Teste Valor médio da Acurácia, Sensibilidade, Precisão, F1-score em (%), AUC ([0,1]) e MCC ([-1,1])					
	Accuracy	AUC	Recall	Prec.	F1	MCC
ET	0,8696	0,8902	0,7500	1,0000	0,8571	0,7676
RF	0,8261	0,8258	0,7500	0,9000	0,8182	0,6641
RBFSVM	0,8261	0,8712	0,6667	1,0000	0,8000	0,6992
XGBOOST	0,7826	0,7955	0,9167	0,7333	0,8148	0,5800
GBC	0,7826	0,8258	0,7500	0,8182	0,7826	0,5682
DT	0,7826	0,7992	0,6667	0,8889	0,7619	0,5893
QDA	0,7826	0,8561	0,6667	0,8889	0,7619	0,5893

Fonte: o autor.

Nos dados de teste, três modelos se destacaram com acurácia superior a 80%. O ET apresentou o melhor desempenho global, alcançando 86,96% de acurácia, com F1 de 85,71%, precisão de 100,00%, recall de 75,00%, AUC de 0,8902 e MCC de 0,7676, evidenciando um perfil equilibrado entre as métricas. O RF obteve acurácia de 82,61%, F1 de 81,82%, recall de 75,00% e precisão de 90,00%, com AUC de 0,8258 e MCC de 0,6641. O RBF-SVM apresentou desempenho semelhante, com acurácia de 82,61% e F1 de 80,00%, destacando-se pela precisão máxima de 100,00% em detrimento de um recall menor de 66,67%, com AUC de 0,8712 e MCC de 0,6992. O XGBoost obteve acurácia de 78,26%, mas compensou com o maior recall entre todos os modelos, de 91,67%, embora com menor precisão de 73,33%, resultando em F1 de 81,48%.

Os demais classificadores GBC, DT e QDA também registraram acurácia de 78,26%, porém com variações nas métricas associadas, como F1, recall e precisão, indicando desempenhos consistentes, embora sem atingir o mesmo nível de outros modelos. A Figura 25 apresenta a comparação dos sete modelos de maior desempenho, destacando os valores médios de acurácia e a respectiva variação percentual obtida antes e depois do processo de otimização, considerando a aplicação da técnica CFS.

Figura 25 – Comparação da acurácia média (%) antes e depois da otimização para os sete melhores modelos de classificação após a aplicação da técnica de CFS.



Fonte: o autor.


A Figura 25 ilustra a comparação da acurácia média dos sete modelos antes e depois da otimização com a técnica CFS. Observa-se ganho expressivo no RF, com variação positiva de 18,7%; no XGBoost, de +12,5%; e no DT, de +20,0%, enquanto o QDA apresentou queda de -5,3%. Modelos como o ET mantiveram desempenho estável, evidenciando que a seleção de características beneficiou alguns classificadores ao mesmo tempo em que reduziu a eficácia de outros. Considerando o conjunto de sete modelos, a acurácia média global passou de 74,82% para 80,17%, o que corresponde a um aumento médio de 5,35%, confirmando o impacto positivo da otimização. Dito isso, os resultados evidenciam que os modelos apresentaram desempenhos promissores na classificação de indivíduos com DP a partir das características extraídas pela órtese. Quando consideradas todas as variáveis, os classificadores QDA, MLP e KNN se destacaram, alcançando acurácias médias de 91,30%, 86,96% e 82,61%,

respectivamente, associadas a valores elevados de F1 e MCC, o que reforça sua robustez preditiva.

Por outro lado, ao aplicar a técnica de seleção de características CFS, observou-se manutenção de desempenhos competitivos, com modelos como ET, RF e RBF-SVM atingindo acurácias entre 82,61% e 86,96%, acompanhadas de F1 próximas a 0,80 e 0,86. Essa consistência sugere que a redução do espaço de variáveis não comprometeu a capacidade discriminativa dos modelos, contribuindo ainda para mitigar o risco de *overfitting* e reforçando a relevância da seleção de características no processo de modelagem.

A Figura 26 apresenta a comparação da acurácia média de oito modelos de classificação, de melhor desempenho, considerando todas as variáveis disponíveis e após a aplicação da técnica de seleção de características CFS, que removeu duas variáveis, conforme descrito na Tabela 12.

Figura 26 – Comparação da acurácia média (%) dos oito modelos de melhor desempenho, considerando todas as variáveis e após a aplicação da técnica CFS.




Fonte: o autor.

Observa-se que o QDA, inicialmente com o melhor desempenho, considerando todas as variáveis, de 91,30%, teve redução para 78,26%, enquanto o MLP e o CatBoost também registraram queda após a redução do espaço de atributos. Em contrapartida, modelos como o ET passaram de 73,91% para 86,96%, o RF de 69,57% para 82,61%, e o RBF-SVM de 78,26% para 82,61%, apresentando ganhos expressivos de desempenho. Esses resultados evidenciam que a seleção de variáveis não impacta todos os classificadores da mesma forma, mas pode

favorecer aqueles mais sensíveis ao sobreajuste, resultando em um melhor equilíbrio entre a complexidade do modelo e a capacidade preditiva.

No entanto, é crucial contextualizar estes resultados com as limitações inerentes ao conjunto de dados utilizado, de modo que, apesar do alto desempenho ser extremamente encorajador e alinhado aos objetivos do estudo, a generalização desses resultados para uma população maior ou mais diversa requer cautela. Uma validação externa com conjuntos de dados maiores e independentes é recomendada para confirmar a robustez e a aplicabilidade clínica dos modelos propostos. A Figura 27 apresenta as matrizes de confusão dos três melhores modelos (ET, RF e RBFSVM), que serviram de base para o cálculo das métricas apresentadas na Tabela 15.

Figura 27 – Matriz de confusão dos três modelos com melhor desempenho no conjunto de teste após aplicação da técnica de CFS.



Fonte: o autor.


O gráfico de importância das variáveis, chamado de *Feature Importance*, obtido após a aplicação da técnica CFS, apresentado na Figura 28 atribui uma pontuação a cada característica, de modo que valores mais altos indicam maior relevância para a variável de saída (Jain; Singh, 2018; Rehman et al., 2019). Esse tipo de análise é fundamental, pois permite identificar as variáveis que mais contribuem para o desempenho do modelo, favorecendo a interpretação dos resultados e a compreensão dos fatores mais influentes no processo de classificação.

Para esta análise, foi necessário selecionar modelos que fornecem uma estimativa interna de importância dos atributos. Por esta razão, o modelo RBF-SVM foi excluído desta etapa, já que sua arquitetura, baseada em funções de kernel, não indica diretamente quais variáveis são mais influentes. Desta forma, as análises de importância foram realizadas nos

modelos ET e XGBOOST, ambos aplicados ao subconjunto de 10 características selecionadas. A escolha desses dois modelos se deu pelos seguintes critérios:

- O ET foi selecionado por apresentar a melhor acurácia (86,96%) entre os modelos testados, o que representa um método de ensemble baseado em randomização.
- O XGBOOST foi selecionado para fins de comparação, por possuir uma arquitetura fundamentalmente diferente (baseada em boosting), o que permite investigar se o perfil de importância se mantém entre distintas filosofias de modelo, mesmo em um cenário de acurácia inferior (neste caso, < 80%).

Figura 28 – Ranking das dez variáveis de maior importância para: A) ET e B) XGBOOST, após a aplicação da técnica de CFS.



Fonte: o autor.

Apesar das diferenças inerentes aos algoritmos, ambos os modelos ET e XGBoost apresentam consistência quanto às variáveis de maior relevância. Observa-se que

SLOPE_Flexao, SLOPE_Extensao e TRABALHO_Flexao estão entre as principais em ambos os *rankings*, indicando um núcleo robusto de atributos que contribuem de forma decisiva para a discriminação entre os grupos analisados.

A análise de importância das variáveis na Figura 28, obtida a partir dos modelos treinados no subconjunto de 10 características selecionadas via CFS, atribuiu pontuações elevadas a SLOPE_Flexao e TRABALHO_Flexao. Isso indica que, mesmo em uma análise multivariada, em que as interações entre variáveis são consideradas, estas duas mantiveram um papel central no processo de classificação. É notável que estas mesmas variáveis também foram apontadas como estatisticamente significativas na análise univariada (que considerou o conjunto inicial de 12 variáveis).

Embora uma comparação direta entre a análise estatística (univariada, 12 features) e a importância de ML (multivariada, 10 features) seja metodologicamente inadequada, o fato de que SLOPE_Flexao e TRABALHO_Flexao se destacaram em ambos os processos sugere que são marcadores discriminativos robustos. Elas demonstram ter forte poder de separação entre os grupos tanto isoladamente (na análise estatística) quanto em combinação com outras variáveis (na análise de ML).

5.4 Avaliação de correlação entre variáveis biomecânicas da órtese e escores clínicos do item III da escala MDS-UPDRS

Com o intuito de investigar se os parâmetros biomecânicos obtidos a partir da órtese apresentam associação com a avaliação clínica da rigidez, realizou-se uma análise de correlação utilizando o coeficiente de Spearman. Essa escolha justifica-se pelo caráter ordinal dos escores da UPDRS, tornando o método mais adequado ao conjunto de dados disponível. O objetivo principal desta etapa foi verificar a existência ou não de correlação entre as medidas instrumentais e os escores clínicos, sem buscar, neste momento, a construção de modelos explicativos ou preditivos. Na Tabela 16, são apresentadas as correlações de Spearman entre os parâmetros biomecânicos da órtese e os escores da UPDRS, considerando tanto o escore motor total (Parte III) quanto o item específico de rigidez (Item 3.3).

Tabela 16 – Coeficientes de correlação de Spearman (ρ) entre variáveis biomecânicas da órtese e os escores clínicos da UPDRS (Parte III e Item 3.3)

Variável	Item III (eixo motor)		Item 3.3 (a-e)	
	Spearman (ρ)	p – valor	Spearman (ρ)	p – valor
CARGA_Extensao	0,0924	0,5462	-0,1438	0,3458
CARGA_Flexao	0,2380	0,1154	0,4080	0,0054
MAV	0,0721	0,6377	-0,0547	0,7212
MAVFD	-0,2804	0,0620	-0,3199	0,0322
MAVSD	-0,2806	0,0618	-0,3197	0,0323
PICO	0,1044	0,4947	0,2380	0,1153
RANGE	0,0811	0,5966	0,2697	0,0732
SLOPE_Extensao	0,0595	0,6980	0,1130	0,4597
SLOPE_Flexao	0,0369	0,8100	-0,0432	0,7784
STD	-0,1762	0,2469	-0,3260	0,0289
TRABALHO_Extensao	0,0745	0,6266	0,0148	0,9232
TRABALHO_Flexao	0,2105	0,1652	0,3418	0,0216

Fonte: o autor.

A análise de correlação realizada entre as variáveis biomecânicas da órtese e os escores clínicos da UPDRS evidenciou associações de magnitude moderada com o item específico de rigidez (Item 3.3), em especial para CARGA_Flexão ($\rho = 0,41$), TRABALHO_Flexão ($\rho = 0,34$) e MAVFD ($\rho = -0,32$), MAVSD ($\rho = -0,32$) e STD ($\rho = -0,33$), todas com valores de p , em módulo, abaixo de 0,05. Em contraste, não foram observadas correlações relevantes com o escore motor global (Parte III), o que era esperado, uma vez que este agrega diferentes manifestações motoras além da rigidez. Cabe destacar que, por se tratar de uma análise exploratória em uma amostra reduzida, não foi aplicada correção formal para múltiplas comparações. Dessa forma, os resultados devem ser interpretados com cautela, sendo considerados como indícios iniciais de convergência entre medidas instrumentais e avaliação clínica, cuja confirmação dependerá de estudos futuros com maior número de participantes.

Resultados semelhantes foram descritos por Perera et al. (2019), que utilizaram o dispositivo BiRD para quantificar a rigidez em indivíduos com doença de Parkinson. Nesse estudo, o instrumento apresentou apenas congruência moderada com a MDS-UPDRS, mas mostrou maior sensibilidade ao item específico de rigidez (Item 3.3), às condições terapêuticas de DBS e à ativação contralateral (Perera et al., 2019). De forma análoga ao observado no presente trabalho, a correlação com o escore motor global da UPDRS (Parte III) foi limitada, reforçando que medidas instrumentais de rigidez tendem a convergir mais fortemente com avaliações clínicas específicas da rigidez do que com o eixo motor completo.

5.5 Resultados para modelo matemático para quantificação da rigidez.

A predição do escore de rigidez a partir de características do sinal biomecânico foi investigada através de uma abordagem de modelagem progressiva. O processo partiu de um modelo de regressão linear múltipla de base, que foi subsequentemente otimizado via técnicas de engenharia e seleção de características para maximizar o poder preditivo e a robustez estatística.

5.5.1 Modelo de base com 12 características e modelo simplificado

Inicialmente, foi desenvolvido um modelo de regressão linear múltipla utilizando o conjunto completo de 12 variáveis preditoras extraídas do sinal biomédico. O objetivo era estabelecer uma linha de base para o poder explicativo dos dados brutos. Os resultados desse modelo inicial são apresentados na Tabela 17.

Tabela 17 – Análise das métricas de desempenho de regressão do modelo final validado

Características	Métrica	Valor	Descrição Técnica
12 características	R^2	0,6820	O modelo explica 68,20% da variabilidade total observada nos scores da rigidez (3.3a-e)
	R_{adj}	0,5630	Após o ajuste pela complexidade do modelo usando as 12 variáveis preditoras, o poder explicativo é de 56,3%.
	RMSE	1,250	A raiz do erro quadrático indica que o erro médio de previsão do modelo é de 1,25 pontos sobre o score da rigidez.

Fonte: o autor.

O valor do R^2 foi de 68,20% o que explica bem a variabilidade total para os scores da rigidez com um valor R^2 Ajustado ($R_{adj} = 0,563$) que demonstra um poder preditivo robusto, indicando que mais da metade da variação clínica da rigidez pode ser explicada pelas características biomecânicas capturadas pela órtese semelhante ao observado em Perera et. al (2019) cujo valor para o R_{adj} foi de 0,676. O RMSE deste estudo, com valor de 1,250 quantifica inicialmente a magnitude do erro esperado, estabelecendo a precisão matemática do modelo.

No entanto, apesar de um R^2 ajustado promissor de 56,3%, uma análise de diagnóstico revelou um Fator de Inflação de Variância (VIF) extremamente elevado para múltiplas variáveis, indicando um problema severo de multicolinearidade. Essa condição torna os coeficientes do modelo instáveis e pouco confiáveis, o que justifica a necessidade de uma estratégia de otimização mais robusta.

Inspirada por metodologias encontradas na literatura, como Perera *et al.* (2019), foi adotada uma abordagem avançada para superar as limitações do modelo de base. A estratégia consistiu em duas etapas:

- i. Engenharia de Features: O conjunto de preditores foi expandido para incluir termos de interação. Além das 12 variáveis originais, foram geradas 66 novas características correspondentes a todos os produtos de pares de segunda ordem, ou seja, interações do tipo $V_i \times V_j$ com $i \neq j$. A soma das 12 características originais com estas 66 novas interações resultaram no conjunto de 78 características candidatas.
- ii. Seleção de Características (*Stepwise*): Foi aplicado um algoritmo de seleção progressiva (*forward selection*) para vasculhar as 78 características e selecionar apenas a combinação mais parsimoniosa e estatisticamente significativa com $p - \text{valor} < 0,05$.

A escolha da seleção *stepwise* (progressiva), em detrimento de técnicas de redução de dimensões, como a Análise de Componentes Principais (PCA), foi deliberada. Enquanto o PCA é altamente eficaz para mitigar a multicolinearidade, isso ocorre ao custo da interpretabilidade, pois seus componentes principais são combinações lineares de todas as variáveis originais.

O objetivo desta etapa, inspirado na abordagem de Perera *et al.* (2019), não era apenas reduzir o modelo, mas sim explorar e identificar quais das 78 características candidatas (incluindo as interações) eram estatisticamente significativas. A seleção *stepwise* foi, portanto, empregada como uma ferramenta sistemática para obter um modelo final que fosse ao mesmo tempo parcimonioso e interpretável, permitindo a análise direta do impacto de cada feature e de cada interação selecionadas. Reconhece-se que o método *stepwise* pode ser sensível à multicolinearidade, um balanço metodológico que foi assumido em favor da interpretabilidade do modelo final.

Diferentemente do modelo inicial, o processo de seleção automática resultou em um modelo superior, que utiliza apenas 3 termos de interação como preditores. Este modelo não só é mais simples, como também apresenta desempenho preditivo superior, como se observa na Tabela 18.

Tabela 18 – Análise das métricas de desempenho de regressão do modelo otimizado

Características	Métrica	Valor	Descrição Técnica
3 Interações selecionadas	R ²	0,6030	O modelo explica 60,30% da variabilidade total observada nos scores da rigidez (3.3a-e)
	R _{adj}	0,5740	Após o ajuste pela complexidade do modelo usando as 3 variáveis preditoras, o poder explicativo é de 57,40%.
	RMSE	1,153	A raiz do erro quadrático indica que o erro médio de previsão do modelo é de 1,15 pontos sobre o score da rigidez.

Fonte: o autor.

As três características selecionadas pelo modelo foram: MAVFD*STD, STD*SLOPE_Flexao e MAVSD*CARGA_Flexao. O fato de o algoritmo ter convergido exclusivamente para termos de interação representa o principal insight deste trabalho: a rigidez, conforme medida pelo Score_Item3_3, não é adequadamente explicada por variáveis isoladas, mas sim pela sua relação multiplicativa. A equação preditiva final, que representa este modelo otimizado, é:

$$\begin{aligned} Score_{Rigidez} = & 6,1395 - (62,5768 * MAVFD * STD) + (6,8808 * STD \\ & * SLOPE_Flexao) + (9301,8068 * MAVSD * CARGA_Flexao) \end{aligned} \quad (10)$$

O modelo final, dado pela Equação (10), com um poder explicativo de 57,40%, supera o modelo de base, mesmo sendo muito mais simples.


5.5.2 Desempenho do modelo sob a ótica de classificação clínica

Para avaliar a aplicabilidade prática do modelo em um cenário clínico, as previsões contínuas geradas pela regressão foram arredondadas para o valor inteiro mais próximo, permitindo uma análise de acurácia. Esta abordagem mede a capacidade do modelo de replicar a pontuação discreta que seria atribuída por um avaliador humano. O resultado de maior relevância clínica foi a Acurácia “Ampliada”, que alcançou 75,56% considerando todas as características. Este indicador, que considera um acerto as previsões exatas ou com um desvio máximo de ± 1 ponto, sugere que, em mais de três quartos dos casos, o dispositivo fornece uma estimativa de rigidez extremamente próxima da avaliação clínica, validando seu potencial como uma ferramenta confiável para triagem e monitoramento.

A Figura 29 apresenta a matriz de confusão, que ilustra visualmente o comportamento do modelo considerando o número total de características, como apresentado na Tabela 17, cujo

objetivo é manter um valor representativo para a Acurácia “Ampliada”. Observa-se que a grande maioria dos erros de classificação ocorre em categorias adjacentes, ou seja, ao prever um score 4 quando o real era 3, com praticamente nenhuma predição grosseiramente incorreta, o que reforça a confiabilidade das estimativas.


Figura 29 – Matriz de Confusão para a Classificação dos Scores de Rigidez (MDS-UPDRS item 3.3(a-e) pelo Modelo Preditivo considerando a Acurácia Ampliada com 12 características



Fonte: o autor.

Já a Figura 30 apresenta a matriz de confusão do modelo otimizado, que utiliza apenas as três características de interação selecionadas. A análise dessa matriz revela um desempenho superior em comparação ao do modelo de base. Uma análise focada na aplicação prática do modelo, utilizando a Acurácia Ampliada (que considera acertos com margem de erro de ± 1 ponto), mostra que o modelo alcançou um índice de 73,33%. Esse valor é notavelmente próximo ao desempenho do modelo de base, que utiliza todas as 12 características. Tal resultado demonstra que foi possível reduzir drasticamente a complexidade do modelo, passando de 12 para apenas 3 preditores de interação, sem sacrificar sua acurácia em um cenário clinicamente relevante. De forma análoga ao modelo anterior, os poucos erros de classificação permanecem concentrados nas categorias adjacentes. Esta representação visual, portanto, corrobora as métricas obtidas com R^2 de 60,30% e R^2 ajustado de 57,40%, confirmando que a abordagem de seleção de características resultou em um modelo final não apenas mais simples, mas também com capacidade preditiva estatisticamente significativa.

Figura 30 – Matriz de Confusão para a Classificação dos Scores de Rigidez (MDS-UPDRS item 3.3(a-e) pelo Modelo Preditivo Simplificado considerando a Acurácia Ampliada com 3 interações



Fonte: o autor.

Em síntese, os resultados demonstram a construção bem-sucedida de ambos os modelos preditivos no caso inicial onde considera-se todas as variáveis foi capaz de explicar 68,20% da variabilidade total dos dados ($R^2 = 0,6820$). A robustez do modelo é confirmada por uma precisão estatisticamente comprovada ($R_{adj} = 0,563$) e por uma alta relevância em um contexto clínico-prático, com Acurácia Ampliada de 75,56%. O mesmo ocorreu para o modelo com um número menor de variáveis com apenas 3 interações e com um resultado explicativo de 60,30%, ou seja, com um $R^2 = 0,6030$ e um R_{adj} de 0,5740 e uma Acurácia Ampliada de 73,33%.

A análise aprofundada do modelo não apenas forneceu uma equação quantitativa para estimar da rigidez, mas também refinou a hipótese biomecânica original. Embora as métricas derivadas da fase de flexão, como SLOPE e CARGA, tenham se mostrado preditoras relevantes, a análise *stepwise* revelou que a variabilidade do sinal (STD) é um componente igualmente crucial. De fato, a variável STD foi a característica mais proeminente em termos de interação, aparecendo em dois dos três selecionados pelo modelo. Este achado sugere que a rigidez não é capturada apenas pelas métricas de flexão isoladamente, mas sim pela interação complexa entre essas métricas e a variabilidade do movimento.

Com o intuito de trazer os resultados para uma análise real, por exemplo considerando a atuação de um profissional da área da saúde, como um fisioterapeuta, o valor obtido para R^2 e R_{adj} do modelo onde considera-se neste estudo todas as variáveis, indicam que as medições

da órtese são eficazes em capturar uma parcela significativa das variações da rigidez que ele observa na clínica, já um valor de RMSE de 1,250 pontos significa que, em média, a previsão do modelo para o escore total de rigidez da MDS-UPDRS (itens 3.3a-e) difere do escore clínico real em 1,250 pontos. De modo que se um paciente tem um escore de rigidez total de 5 pontos, o modelo proposto neste trabalho poderia prever um valor entre 3,75 e 6,25 pontos. E ao pensarmos no potencial máximo da escala de 20 pontos, considerando apenas a rigidez, o erro de 1,250 pontos corresponderia a 6,25% do total. A relevância clínica deste erro é ainda mais destacada pela métrica de Acurácia Ampliada de 75,56%, o que, na maioria das vezes, significa que, se um paciente tiver um escore de rigidez de 5, o modelo vai prever algo entre 4, 5 ou 6 pontos, o que é clinicamente muito próximo e útil.

Contudo, a interpretação da generalização e da robustez destes achados deve considerar as limitações decorrentes do tamanho da amostra. O modelo foi desenvolvido com base nos dados de um coorte relativamente pequeno, o que pode restringir a aplicação direta dos resultados a uma população mais ampla. Embora a validação cruzada tenha sido empregada para mitigar o risco de *overfitting*, a potencial influência da amostragem limitada e da repetição de medições dos mesmos sujeitos deve ser reconhecida.

Assim, para a validação completa e a otimização da objetividade do modelo, especialmente para fins de auxílio a um diagnóstico clínico detalhado ou ao monitoramento da progressão da doença, a incorporação de um conjunto de dados maior, ou seja, com um n tamanho e diversidade maiores, é fundamental em estudos futuros.

5.6 Escala MDS-UPDRS e de Avaliação de Usabilidade

Vamos apresentar os resultados obtidos referentes aos dados coletados considerando a Escala MDS-UPDRS que foi aplicada aos voluntários do grupo DP, a escala SFSS e a escala SUS aplicada a todos os voluntários, sendo estas duas escalas baseadas mais na experiência dos voluntários em relação ao uso da órtese.

5.6.1 Escala MDS-UPDRS

Para assegurar a robustez dos dados clínicos, a avaliação da função motora foi realizada utilizando a Parte III da escala MDS-UPDRS, sob um protocolo de avaliação cega com dois examinadores. A consistência entre os avaliadores foi sistematicamente verificada, seguindo as diretrizes da literatura, que recomendam um ajuste quando a diferença entre os escores totais dos avaliadores é superior a cinco pontos (Marsili et al., 2023; Noyce et al., 2017). A partir das

avaliações validadas, foram derivados os escores finais para cada voluntário através do cálculo da média. Foram consolidados o escore motor total (máximo de 132 pontos) e o subescore de rigidez, este último composto pelos cinco itens do domínio 3.3 (a-e), com uma pontuação máxima de 20 pontos. A Tabela 19 a seguir resume os escores clínicos consolidados para o grupo de voluntários com DP.

Tabela 19 – Resultados descritivos dos escores obtidos por meio da escala MDS-UPDRS.

Característica	Valor
Escore Motor Total (UPDRS-III)	
Média (DP)	20,90 (9,70)
Mediana (IIQ)	18,0 (13,5 – 24,0)
Mínimo – Máximo	11 – 42
Escore da Rigidez	
Média (DP)	4,50 (2,30)
Mediana (IIQ)	4,00 (3,00 – 5,00)
Mínimo – Máximo	0 – 10


Fonte: o autor.

A análise dos dados apresentados na Tabela 19 permite caracterizar o perfil de severidade motora da amostra. O escore motor total (UPDRS-III), com média de aproximadamente 21 pontos, indica um comprometimento motor geral de leve a moderado na amostra. Especificamente, o escore de rigidez apresentou valor médio de 4,5 pontos, confirmando a rigidez como sintoma presente e mensurável no grupo. A amostra é bem caracterizada, com uma boa distribuição de idade, como observado na Figura 21 e uma proporção de sexo consistente com o esperado para a DP. Os escores motores indicam que os pacientes não estão em estágios muito avançados da doença.

A comparação da severidade motora entre os sexos foi avaliada pelo teste de U de Mann-Whitney. Para esta análise, a hipótese nula (H_0) de que não haveria diferença na distribuição dos escores motores entre os grupos masculino e feminino. Adotando um nível de significância $\alpha = 0,05$, não foram encontradas diferenças estatisticamente significativas nem para o escore motor total $p - valor = 0,183$, nem para o escore de rigidez $p - valor = 0,139$. Como ambos os p-valores obtidos são maiores do que o valor de $\alpha = 0,05$, não há evidências estatisticamente significativas para rejeitar a hipótese nula. Portanto, conclui-se que as diferenças observadas entre os grupos não são estatisticamente significativas.

A Figura 31 apresenta uma leve tendência a escores mais altos no grupo feminino para ambos os escores observados, no entanto, os resultados estatísticos confirmam que essa variação não é significativa.

Figura 31 – *Boxplots* com a comparação do escore motor total e da rigidez por sexo para os participantes do grupo com a Doença de Parkinson.



Fonte: o autor.


Apesar de uma aparente tendência visual nos *boxplots* da Figura 31, em que o grupo feminino apresenta medianas superiores às do masculino, o teste de U de Mann-Whitney falhou em detectar uma diferença estatisticamente significativa ($p > 0,05$). Portanto, no contexto desta amostra, não há evidências estatísticas para afirmar que o sexo seja um fator de diferenciação na gravidade dos sintomas.

A ausência de significância, mesmo diante da diferença visual, sugere que o teste pode ter sido impactado pela alta dispersão dos dados ou pelo tamanho amostral, que reduzem o poder estatístico da análise.

A fim de investigar uma possível associação entre a idade e a severidade dos sintomas motores, foi realizado o teste de correlação de Spearman. A hipótese nula (H_0) era de que não haveria correlação entre a idade dos participantes e os escores clínicos.

A análise da relação entre a idade e o escore motor total (UPDRS-III) resultou em um coeficiente de correlação fraco e não significativo $\rho = 0,344$ e $p - \text{valor} = 0,210$. De forma ainda mais expressiva, a correlação entre a idade e o subescore de rigidez foi praticamente nula e não apresentou significância estatística $\rho = 0,008$ e $p - \text{valor} = 0,977$. A Figura 32 traz a análise de correlação entre idade e a severidade motora.

Figura 32 – Correlação entre idade e escores clínicos. Gráficos de dispersão mostrando a relação entre a idade dos voluntários e (A) o escore motor total e (B) o escore de rigidez. A linha de tendência está representada em ambos os itens.



Fonte: o autor.

Como em ambos os casos o p-valor foi superior ao nível de significância ($\alpha = 0.05$), a hipótese nula não foi rejeitada. A alta dispersão dos dados, refletida nos p-valores elevados, indica que para a amostra estudada, a idade não foi um fator correlacionado com a gravidade dos sintomas motores gerais ou da rigidez.

5.6.2 Avaliação baseada em abordagens centradas na experiência do usuário

A Tabela 20 apresenta os resultados comparativos das respostas obtidas nos questionários aplicados durante o processo de coleta de dados. Esta etapa teve como foco avaliar tanto a experiência de usabilidade dos participantes quanto o conforto percebido durante o uso da órtese.

Cabe destacar que o dispositivo passou por atualizações relevantes em relação à versão original, incorporando melhorias ergonômicas em seu design físico (Andrade et al., 2019) e substituindo o goniômetro acoplado anteriormente utilizado em estudos de validação da tecnologia (Ribeiro, 2023) por um sistema de análise baseado em visão computacional.

Essa reformulação visou não apenas ampliar a precisão das medições, mas também otimizar a experiência do usuário, promovendo maior conforto e segurança durante os procedimentos, reduzindo o risco de desconforto ou lesões e proporcionando uma experiência de uso mais leve, eficiente e centrada no usuário.

Para o cálculo da pontuação dos participantes na escala SUS, adota-se o seguinte procedimento: subtrai-se 1 do valor atribuído pelo participante às questões ímpares e, no caso das questões pares, subtrai-se o valor da resposta do número 5. Em seguida, somam-se todos os resultados obtidos, e o total é multiplicado por 2,5. Com isso, a pontuação final do questionário varia de 0 a 100 pontos. De acordo com a média de referência estabelecida na literatura, um escore inferior a 68 pontos pode indicar problemas de usabilidade no sistema avaliado (BROOKE, 2020). Já a pontuação final de cada participante na escala SFSS, do tipo Likert de 5 pontos, é obtida pela média aritmética simples das respostas aos nove itens do questionário (Jackson; Martin; Eklund, 2008). Os dados observados na Tabela 20 apresentam um resumo descritivo, incluindo a média acrescida do desvio padrão, a mediana e os valores mínimo e máximo para cada um dos questionários, considerando a divisão dos grupos de participantes em DP e HC.

Tabela 20 – Resultados descritivos dos escores obtidos nos questionários SFSS e SUS aplicados após a utilização da órtese.

Questionário	Status	Média $\pm$ std	Mediana	Mín. – Máx.
SUS	DP	83,04 $\pm$ 7,66	85	(72,50 – 97,50)
	HC	86,33 $\pm$ 6,81	90	(70 – 95)
SFSS	DP	4,03 $\pm$ 0,54	4	(3 – 5)
	HC	4,38 $\pm$ 0,59	5	(3 – 5)

Fonte: o autor.

Para a análise dos questionários SFSS e SUS, conforme apresentado na Tabela 20, foi realizado inicialmente o cálculo individual das métricas estatísticas (média, desvio padrão, mediana, valor mínimo e máximo) para cada voluntário, com base em seus respectivos escores. Posteriormente, a média geral e o desvio padrão foram obtidos a partir da média dos valores individuais dessas métricas. No caso da mediana, utilizou-se a mediana dos valores de mediana individuais. Já para o valor mínimo e o valor máximo, foram considerados os valores globais observados entre todos os participantes do grupo, de modo a representar a amplitude total dos escores.

Com base nesse procedimento, os resultados globais para o questionário SFSS indicaram uma média de 4,20, com desvio padrão de 0,5649, enquanto o valor mediano foi de 4, com valores mínimo e máximo variando entre 3 e 5, respectivamente. Em relação ao questionário SUS, observou-se uma média de 84,83 com desvio padrão de 7,16, mediana de 85 e amplitude de variação entre 70 e 97,50. Cabe destacar que o valor médio de 84,83 está bem acima do


ponto de corte de 68, tradicionalmente utilizado como referência para indicar boa usabilidade (BROOKE, 2020), o que sugere fortemente uma percepção positiva da aplicação pelos voluntários, tanto do grupo com Doença de Parkinson quanto do grupo controle.

Com base nas avaliações obtidas por meio das escalas SUS e SFSS, observou-se que as melhorias implementadas na órtese, desenvolvidas no âmbito do projeto inicial (Costa; Andrade, 2020), contribuíram significativamente para o aumento da usabilidade da aplicação, o engajamento dos participantes e a percepção de conforto durante o uso.

Destaca-se que a adoção de um sistema de análise baseado em visão computacional, em substituição ao goniômetro acoplado, como observado em Ribeiro (2023), aliada às melhorias ergonômicas propostas por (Andrade et al., 2019; Costa; Andrade, 2020), mostrou-se uma escolha acertada, promovendo maior segurança, comodidade e eficiência durante a aplicação do protocolo experimental.

A Figura 33 apresenta a distribuição dos escores obtidos nas escalas SFSS (A) e SUS (B) para os grupos com DP e HC, permitindo comparar o desempenho e a percepção de usabilidade entre as duas populações avaliadas.

Figura 33 – Distribuição dos escores obtidos nas escalas SFSS (A) e SUS (B) nos grupos com DP e HC, representada por meio de gráficos do tipo *violin plot*, com sobreposição de *boxplot* e pontos individuais.



Fonte: o autor.

(A) Escala Curta de Fluxo (SFSS)

(B) Escala de Usabilidade do Sistema (SUS)

Com base na Figura 33, item (A), observa-se que os escores obtidos na SFSS revelam uma tendência superior no grupo controle em comparação ao grupo com Doença de Parkinson. A distribuição dos dados, representada pelo gráfico tipo *violin plot*, indica uma maior

concentração de escores elevados no grupo de controle, com mediana próxima de 4,5, enquanto o grupo com a DP apresenta valores mais concentrados em torno de 4, com menor dispersão superior. Além disso, o *boxplot* interno demonstra que a variabilidade intragrupo é levemente maior entre os controles, sugerindo que, embora ambos os grupos tenham atingido escores relativamente altos (acima de 3), os participantes sem diagnóstico de Parkinson tendem a relatar maior fluidez e engajamento durante a experiência de uso da órtese. Esses achados corroboram a hipótese de que, mesmo com melhorias ergonômicas e adaptações tecnológicas, a rigidez e outros sintomas motores da DP ainda impactam a percepção de fluidez da atividade, reforçando a importância de abordagens centradas no usuário com foco especial em públicos com comprometimentos neuro motores.

Já para a Figura 33, item (B), tem-se a distribuição das pontuações obtidas na Escala SUS pelos participantes dos grupos DP e HC. Visualmente, observa-se que ambos os grupos apresentaram escores elevados, acima do valor de corte de 68, indicando percepção de boa usabilidade da aplicação (BROOKE, 2020). O grupo controle demonstrou uma leve tendência a pontuações mais altas e menos dispersas, refletida por uma concentração maior de escores entre 85 e 95. Já o grupo com Doença de Parkinson apresentou maior variabilidade nas respostas, com escores distribuídos entre 70 e 95. Essa distribuição reforça que, apesar de pequenas diferenças, a aplicação mostrou-se acessível e compreensível para ambos os públicos-alvo.

Esses resultados evidenciam a importância de adaptar soluções tecnológicas às necessidades específicas de diferentes perfis de usuários, especialmente em populações com comprometimentos motores ou cognitivos. A órtese aprimorada demonstrou potencial como ferramenta acessível, precisa e eficaz para aplicações clínicas e experimentais que demandam medições objetivas de rigidez muscular. Além do desempenho técnico, o alto grau de aceitação pelos usuários, refletido nas elevadas pontuações de usabilidade, reforça a relevância de abordagens centradas no usuário e do aprimoramento contínuo da ergonomia e funcionalidade do dispositivo. Essa perspectiva é particularmente significativa no atendimento de pacientes com DP, ampliando o alcance e a aplicabilidade de tecnologias assistivas baseadas em sensores e visão computacional no contexto da Engenharia Biomédica.

6. CONCLUSÃO

A Doença de Parkinson é uma condição neurodegenerativa progressiva que afeta milhões de pessoas em todo o mundo, trazendo consigo um conjunto complexo de sintomas motores e não motores que comprometem significativamente a funcionalidade e a qualidade de vida dos indivíduos. Entre os sintomas motores clássicos, a rigidez muscular figura como um dos mais prevalentes e desafiadores de mensuração, especialmente por sua avaliação ainda ser predominantemente subjetiva nas práticas clínicas convencionais.

Diante dessa lacuna, o presente trabalho propôs o desenvolvimento e validação de um sistema baseado em órtese instrumentalizada, com o objetivo de quantificar a rigidez muscular de forma objetiva e padronizada. A metodologia adotada envolveu a aplicação de sensores e algoritmos integrados para a mensuração de resistência passiva ao movimento, associando parâmetros biomecânicos com potencial clínico para a avaliação do sintoma.

Os resultados obtidos demonstraram que as características extraídas pela órtese foram capazes de captar variações motoras consistentes. No objetivo de classificação entre indivíduos com DP e o grupo controle, a abordagem demonstrou alta performance. Utilizando todas as 12 características, os modelos de melhor desempenho foram o QDA, com 91,30% de acurácia, seguido pelo MLP com 86,96% e o KNN com 82,61%. Após a aplicação de uma técnica de seleção para remover variáveis redundantes com a aplicação da técnica de CFS, o modelo ET emergiu como o mais performático, atingindo 86,96% de acurácia, seguido pelo RF e RBF-SVM, ambos com 82,61%. Essa consistência nos altos índices de acurácia, mesmo com um conjunto de características mais enxuto, valida a robustez dos sinais capturados. A correlação com a avaliação clínica foi estabelecida por meio de associações estatisticamente significativas, onde a CARGA_Flexão apresentou uma correlação moderada ($p = 0,41$, $p < 0,05$) com o escore de rigidez MDS-UPDRS. Finalmente, o principal objetivo, a quantificação da rigidez, foi alcançado com o desenvolvimento de um modelo matemático que explicou 57,4% (R^2 ajustado) da variabilidade do escore clínico, descobrindo que a predição depende crucialmente da interação entre variáveis biomecânicas. Juntos, estes resultados confirmam o potencial da ferramenta para complementar os métodos tradicionais de avaliação, reduzindo o grau de subjetividade associado às escalas clínicas.

Além do avanço tecnológico em si, o sistema oferece perspectivas promissoras para o acompanhamento longitudinal da progressão da doença e para a avaliação da eficácia de intervenções terapêuticas, especialmente em contextos de reabilitação neurológica. O fato de se tratar de uma ferramenta portátil e não invasiva amplia seu potencial de aplicação em ambientes clínicos e laboratoriais. Algumas limitações do estudo devem ser reconhecidas. O número reduzido de participantes pode restringir a generalização dos resultados, especialmente para diferentes estágios da doença. Além disso, a utilização de um único dispositivo experimental limita a replicabilidade em outros contextos clínicos. O conjunto de algoritmos testados, embora representativo, não esgota todas as possibilidades de modelagem. Tais aspectos devem ser considerados na interpretação dos achados, reforçando a necessidade de estudos multicêntricos e com amostras mais amplas.

Como perspectivas futuras, sugere-se a validação da órtese em ambientes clínicos, ampliando a diversidade da amostra e avaliando a aplicabilidade em diferentes níveis de progressão da doença. Além disso, propõe-se o aperfeiçoamento do sistema com a implementação de relatórios automatizados, *feedback* em tempo real para profissionais de saúde e pacientes, melhoria de aspectos ergonômicos, além da expansão da análise para outros sintomas motores da DP. Do ponto de vista computacional, algoritmos de aprendizado profundo poderão ser explorados para identificar padrões mais complexos, com potencial de automatização do processo diagnóstico.

Conclui-se, portanto, que a órtese ativa de punho conseguiu inicialmente quantificar a rigidez e representa uma alternativa viável, eficaz e inovadora no contexto da avaliação objetiva da Doença de Parkinson, com potencial para melhorar o diagnóstico, o monitoramento e a reabilitação de pacientes, ao mesmo tempo em que fornece subsídios mais confiáveis à prática clínica.

REFERÊNCIAS

- ABRAHÃO, Taciana Abdala. **O uso de modelos auto regressivos para a classificação de indivíduos acometidos pela doença de Parkinson**. Uberlândia, Universidade Federal de Uberlândia, 2017. DOI: <http://doi.org/10.14393/ufu.di.2019.2485>.
- ALHO, Ana Tereza Di Lorenzo. **Caracterização da substância negra humana durante o envelhecimento**. São Paulo: USP, 2011. DOI: <https://doi.org/10.11606/T.5.2011.tde-01122011-175727>.
- ALMEIDA, Jefferson S. *et al.* Detecting Parkinson's disease with sustained phonation and speech signals using machine learning techniques. **Pattern Recognition Letters**, v. 125, p. 55–62, jul. 2019. DOI: <https://doi.org/10.1016/j.patrec.2019.04.005>.
- ALSHAMMARI, Raya *et al.* Machine learning approaches to identify Parkinson's disease using voice signal features. **Frontiers in Artificial Intelligence**, v. 6, 28 mar. 2023. DOI: <https://doi.org/10.3389/frai.2023.1084001>.
- ANDRADE, Adriano O. *et al.* Pelvic movement variability of healthy and unilateral hip joint involvement individuals. **Biomedical Signal Processing and Control**, v. 32, fev. 2017. DOI: <https://doi.org/10.1016/j.bspc.2016.10.008>.
- ANDRADE, Adriano O. *et al.* Ergonomic Assessment of an Active Orthosis for the Rehabilitation of Flexion and Extension of Wrist. **IFMBE proceedings**. p. 565–568. DOI: https://doi.org/10.1007/978-981-10-9038-7_104.
- ARULKUMARAN, Kai *et al.* A Brief Survey of Deep Reinforcement Learning. **IEEE Signal Processing Magazine**. p. 1-16, 19 ago. 2017. DOI: <https://doi.org/10.48550/arXiv.1708.05866>.
- ALVES, Guido *et al.* Epidemiology of Parkinson's disease. **Journal of Neurology**, v. 255, n. S5, p. 18–32, 12 set. 2008. <https://doi.org/10.1007/s00415-008-5004-3>.
- BAKER, Sunderland *et al.* Automatic extraction of upper-limb kinematic activity using deep learning-based markerless tracking during deep brain stimulation implantation for Parkinson's disease: A proof of concept study. **PLoS ONE**, v. 17, n. 10 October, 1 out. 2022. DOI: <https://doi.org/10.1371/journal.pone.0275490>.
- BAO, Guidong *et al.* Classification of Dysphonic Voices in Parkinson's Disease with Semi-Supervised Competitive Learning Algorithm. **Biosensors**, v. 12, n. 7, p. 502, 9 jul. 2022. DOI: <https://doi.org/10.3390/bios12070502>.
- BARTELS, E. M.; HARRISON, A. P.; CELICANIN, M. A Comparison of the Accuracy of Objective Physiological Measuring Techniques for Rigidity in Parkinson's Disease – A Systemic Review. **Journal of Neurology Research Reviews & Reports**, v. 6, n. 6, p. 1–9, 30 jun. 2024. DOI: [https://doi.org/10.47363/JNRRR/2024\(6\)201](https://doi.org/10.47363/JNRRR/2024(6)201).
- BHIDAYASIRI, Roongroj; TARSY, Daniel. Parkinson's Disease: Hoehn and Yahr Scale. *In: Current Clinical Neurology*, p. 4–5. DOI: https://doi.org/10.1007/978-1-60327-426-5_2.
- BLAIR, R. Clifford; TAYLOR, Richard A. **Bioestatística para ciências da saúde**. São Paulo: Pearson, 2013. v. 1, 469 p., ISBN 978-85-8143-171-0.

BORA, Dibya Jyoti; KUMAR GUPTA, Anil; KHAN, Fayaz Ahmad. Comparing the Performance of $L^*A^*B^*$ and HSV Color Spaces with Respect to Color Image Segmentation. **IJETAE**, v. 5, n. 2, p.192-203, 2015. DOI: <https://doi.org/10.48550/arXiv.1506.01472>.

BRONSTEIN, Jeff *et al.* Meeting report: Consensus Statement – Parkinson’s Disease and the Environment: Collaborative on Health and the Environment and Parkinson’s Action Network (CHE PAN) Conference. **Environmental Health Perspectives**, v. 117, n. 1, p. 117–121, 2009. DOI: <https://doi.org/10.1289/ehp.11702>.

BROOKE, John. SUS: A “Quick and Dirty” Usability Scale. In: JORDAN, P. W.; THOMAS, B.; McCLELLAND, I. L.; WEERDMEESTER, B. A. (org.). Usability evaluation in industry. London: Taylor & Francis, 1996. p. 189–194.

BRUCE, Peter; BRUCE, Andrew. **Practical Statistics for Data Scientists: 50 Essential Concepts**. 1st. Edition, Sebastopol, CA: O’Reilly Media, Inc., 2017.

BRUCE, Peter.; BRUCE, Andrew.; GEDECK, Peter. **Practical Statistics for Data Scientists**, 2nd Edition, Sebastopol, CA: O’Reilly Media, Inc., 2020.

BRUDER, Andrea M. *et al.* Physiotherapy intervention practice patterns used in rehabilitation after distal radial fracture. **Physiotherapy**, v. 99, n. 3, p. 233–240, set. 2013. DOI: <https://doi.org/10.1016/j.physio.2012.09.003>.

CASTIGLIONI, Paolo; FAES, Luca; VALENZA, Gaetano. Assessing Complexity in Physiological Systems through Biomedical Signals Analysis. **Entropy**, v. 22, n. 9, p. 1005, 9 set. 2020. DOI: <https://doi.org/10.3390/e22091005>.

CELICANIN, M. *et al.* Probing motor dynamics at the muscle level—Acoustic myography in Parkinson’s disease. **Physiological Reports**, v. 11, n. 6, 22 mar. 2023. DOI: <https://doi.org/10.14814/phy2.15631>.

CERRI, Silvia; MUS, Liudmila; BLANDINI, Fabio. Parkinson’s Disease in Women and Men: What’s the Difference?. **Journal of Parkinson’s Disease**, v. 9, n. 3, p. 501–515, 30 jul. 2019. DOI: <https://doi.org/10.3233/JPD-191683>.

CHAN, Bertram K. C. **Biostatistics for Epidemiology and Public Health Using R**. 1a ed. *New York*: Springer Publishing Company, 2015. 1 e-book (460 p.). ISBN 978-0-8261-1026-8.

CHAPARRO, Luis; AKAN, Aydin. **Signals and Systems using MATLAB**. 3. ed., London: Academic Press, 2018. 722 p. ISBN 978-0128150730.

CHEN, You Yin *et al.* A vision-based regression model to evaluate Parkinsonian gait from monocular image sequences. **Expert Systems with Applications**, v. 39, n. 1, p. 520–526, jan. 2012. DOI: <https://doi.org/10.1016/j.eswa.2011.07.042>.

COBELLI, Claudio; CARSON, Ewart. **Introduction to Modeling in Physiology and Medicine**. 1. ed., London: Academic Press, 2019. 1 e-book (464 p.). DOI: <https://doi.org/10.1016/B978-0-12-815756-5.00001-1>.

COSTA, S. C.; ANDRADE, Adriano de Oliveira. **Avaliação ergonômica de uma órtese ativa de punho para a reabilitação da rigidez em pessoas com a doença de Parkinson**. 2020. 40 f.

Dissertação (Mestrado em Engenharia Biomédica) – Universidade Federal de Uberlândia, Uberlândia, 2020. DOI: <http://doi.org/10.14393/ufu.di.2020.500>.

DICKSON, Jon M.; GRÜNEWALD, Richard A. Somatic symptom progression in idiopathic Parkinson's disease. **Parkinsonism & Related Disorders**, v. 10, n. 8, p. 487–492, 1 dez. 2004. DOI: <https://doi.org/10.1016/j.parkreldis.2004.05.005>.

DORSEY, E. Ray *et al.* Global, regional, and national burden of Parkinson's disease, 1990–2016: a systematic analysis for the Global Burden of Disease Study 2016. **The Lancet Neurology**, v. 17, n. 11, p. 939–953, 1 nov. 2018. DOI: [https://doi.org/10.1016/S1474-4422\(18\)30295-3](https://doi.org/10.1016/S1474-4422(18)30295-3).

ESPÍRITO-SANTO, Helena; DANIEL, Fernanda. Calcular e apresentar tamanhos do efeito em trabalhos científicos (1): As limitações do $p < 0,05$ na análise de diferenças de médias de dois grupos. **Portuguese Journal of Behavioral and Social Research**, v. 1, p. 3–16, 27 fev. 2015. DOI: <https://doi.org/10.7342/ismt.rpics.2015.1.1.14>.

FAHN, Stanley; SULZER, David. Neurodegeneration and neuroprotection in Parkinson disease. **NeuroRX**, v. 1, n. 1, p. 139–154, jan. 2004. DOI: <https://doi.org/10.1602/neurorx.1.1.139>.

FAULHABER. Motion Manager. Versão 6.9.0. Disponível em: <https://www.faulhaber.com/en/support/ Faulhaber-motion-manager/>. Acesso em: 29 ago. 2025.

FERNÁNDEZ-GONZÁLEZ, Pilar *et al.* Reliability of Kinovea® Software and Agreement with a Three-Dimensional Motion System for Gait Analysis in Healthy Subjects. **Sensors**, v. 20, n. 11, p. 3154, 2 jun. 2020. DOI: <https://doi.org/10.3390/s20113154>.

FERREIRA-SÁNCHEZ, María Del Rosario; MORENO-VERDÚ, Marcos; CANO-DE-LA-CUERDA, Roberto. Quantitative Measurement of Rigidity in Parkinson's Disease: A Systematic Review. **Sensors (Switzerland)**, MDPI AG, 1 fev. 2020. DOI: <https://doi.org/10.3390/s20030880>.

FRIEDMAN, Jerome; HASTIE, Trevor; TIBSHIRANI, Robert. **The elements of statistical learning**. Springer Series in Statistics Springer, Berlin, v. 1, 2001. DOI: <https://doi.org/10.1007/978-0-387-84858-7>.

GAPRIELIAN, Pauline *et al.* Integrated robotics platform with haptic control differentiates subjects with Parkinson's disease from controls and quantifies the motor effects of levodopa. **Journal of NeuroEngineering and Rehabilitation**, v. 16, n. 1, p. 124, 26 dez. 2019. DOI: <https://doi.org/10.1186/s12984-019-0598-5>.

GIL, DAVID; JOHNSON, MAGNUS. Diagnosing Parkinson by using Artificial Neural Networks and Support Vector Machines. **Global Journal of Computer Science and Technology**, v. 9, n. 4, p. 63–71, 2009.

GIUFFRIDA, Joseph P.; RAPP, Edward J. Ambulatory and Remote Monitoring of Parkinson's Disease Motor Symptoms. *In: Healthcare Sensor Networks*. London: CRC Press, 2016. p. 247–281. DOI: <https://doi.org/10.1201/b11195-10>.

GOECKS, Jeremy *et al.* How Machine Learning Will Transform Biomedicine. **Cell**, v. 181, n. 1, p. 92–101, 2 abr. 2020. DOI: <https://doi.org/10.1002/mds.22340>.

GOETZ, Christopher 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 Disorders**, v. 23, n. 15, p. 2129–2170, 15 nov. 2008. DOI: <https://doi.org/10.1002/mds.22340>.

GUIMARAES, Matheus T. *et al.* An Optimized Approach to Huntington's Disease Detecting via Audio Signals Processing with Dimensionality Reduction. *In: IEEE*, jul. 2020. DOI: <https://doi.org/10.1109/IJCNN48605.2020.9206773>.

GÜNEY, Gökhan *et al.* Video-Based Hand Movement Analysis of Parkinson Patients before and after Medication Using High-Frame-Rate Videos and MediaPipe. **Sensors**, v. 22, n. 20, p. 7992, 20 out. 2022. DOI: <https://doi.org/10.3390/s22207992>.

HANDELMAN, G. S. *et al.* eDoctor: machine learning and the future of medicine. **Journal of Internal Medicine**, Blackwell Publishing Ltd, 1 dez. 2018. DOI: <https://doi.org/10.1111/joim.12822>.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2. ed. New York: Springer, 2009. 1 e-book (745 p.). DOI: <https://doi.org/10.1007/978-0-387-84858-7>.

HAYES, Michael T. Parkinson's Disease and Parkinsonism. **The American Journal of Medicine**, v. 132, n. 7, p. 802–807, jul. 2019. DOI: <https://doi.org/10.1016/j.amjmed.2019.03.001>.

HEMA, D.; KANNAN, Dr. S. Interactive Color Image Segmentation using HSV Color Space. **Science & Technology Journal**, v. 7, n. 1, p. 37–41, 1 jan. 2019. DOI: <https://doi.org/10.22232/stj.2019.07.01.05>.

HWANG, Juseon *et al.* Machine learning for early detection and severity classification in people with Parkinson's disease. **Scientific Reports**, v. 15, n. 1, p. 234, 2 jan. 2025. DOI: <https://doi.org/10.1038/s41598-024-83975-3>.

IJIMA, Shinno; SHIOMI, Makoto; HARA, Tsuyoshi. Verification of Reliability and Validity of Trunk Forward Tilt Angle Measurement During Gait Using 2-Dimensional Motion Analysis. **Journal of Chiropractic Medicine**, v. 22, n. 2, p. 89–95, jun. 2023. DOI: <https://doi.org/10.1016/j.jcm.2022.04.008>.

ISLAM, Rumana; ABDEL-RAHEEM, Esam; TARIQUE, Mohammed. Voiced Features and Artificial Neural Network to Diagnose Parkinson's Disease Patients. **IEEE**, 23 nov. 2022. DOI: <https://doi.org/10.1109/ICECTA57148.2022.9990334>.

JACKSON, Susan A.; MARTIN, Andrew J.; EKLUND, Robert C. Long and Short Measures of Flow: The Construct Validity of the FSS-2, DFS-2, and New Brief Counterparts. **Journal of Sport and Exercise Psychology**, v. 30, n. 5, p. 561–587, out. 2008. DOI: <https://doi.org/10.1123/jsep.30.5.561>.

JAIN, Divya; SINGH, Vijendra. Feature selection and classification systems for chronic disease prediction: A review. **Egyptian Informatics Journal**, v. 19, n. 3, p. 179–189, nov. 2018. DOI: <https://doi.org/10.1016/j.eij.2018.03.002>.

JANKOVIC, J. Parkinson's disease: Clinical features and diagnosis. **Journal of Neurology, Neurosurgery and Psychiatry**, BMJ Publishing Group, v. 79, n. 4, p. 368–376, abr. 2008. DOI: <https://doi.org/10.1136/jnnp.2007.131045>.

JEANCOLAS, Laetitia *et al.* Voice characteristics from isolated rapid eye movement sleep behavior disorder to early Parkinson's disease. **Parkinsonism & Related Disorders**, v. 95, p. 86–91, fev. 2022. DOI: <https://doi.org/10.1016/j.parkreldis.2022.01.003>.

JEON, Hyoseon *et al.* Automatic Classification of Tremor Severity in Parkinson's Disease Using a Wearable Device. **Sensors**, v. 17, n. 9, p. 2067, 9 set. 2017. DOI: <https://doi.org/10.3390/s17092067>.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**, v. 349, n. 6245, 17 jul. 2015. DOI: <https://doi.org/10.1126/science.aaa8415>.

JOSHI, Deepak; KHAJURIA, Aayushi; JOSHI, Pradeep. An automatic non-invasive method for Parkinson's disease classification. **Computer Methods and Programs in Biomedicine**, v. 145, p. 135–145, jul. 2017. DOI: <https://doi.org/10.1016/j.cmpb.2017.04.007>.

JOSHI, Rajeshree *et al.* PKG Movement Recording System Use Shows Promise in Routine Clinical Care of Patients With Parkinson's Disease. **Frontiers in Neurology**, v. 10, p. 1–11, 1 out. 2019. DOI: <https://doi.org/10.3389/fneur.2019.01027>.

JUUTINEN, Milla *et al.* Parkinson's disease detection from 20-step walking tests using inertial sensors of a smartphone: Machine learning approach based on an observational case-control study. **PLOS ONE**, v. 15, n. 7, p. 1–19, 23 jul. 2020. DOI: <https://doi.org/10.1371/journal.pone.0236258>

KARABAYIR, Ibrahim *et al.* Gradient boosting for Parkinson's disease diagnosis from voice recordings. **BMC Medical Informatics and Decision Making**, v. 20, n. 1, p. 228, 15 dez. 2020. DOI: <https://doi.org/10.1186/s12911-020-01250-7>.

KARAPINAR SENTURK, Zehra. Early diagnosis of Parkinson's disease using machine learning algorithms. **Medical Hypotheses**, v. 138, p. 1–5, maio 2020. DOI: <https://doi.org/10.1016/j.mehy.2020.109603>.

KAWAMURA, Lorena R. S. M. Análise da Apneia na doença de Parkinson. 2023. Tese (Doutorado em Ciências da Saúde) – Programa de Pós-Graduação em Ciências da Saúde, Faculdade de Ciências da Saúde, Universidade de Brasília, Brasília, DF, 2023. Disponível em: <http://repositorio.unb.br/handle/10482/50135>.

KEMPSTER, Peter A.; HURWITZ, Brian; LEES, Andrew J. A new look at James Parkinson's Essay on the Shaking Palsy. **Neurology**, v. 69, n. 5, p. 482–485, 31 jul. 2007. DOI: <https://doi.org/10.1212/01.wnl.0000266639.50620.d1>.

KOEHNSEN, Alexander; KAMBACH, Jannis; BÜSSE, Sebastian. Step by step and frame by frame – Workflow for efficient motion tracking of high-speed movements in animals. **Zoology**, v. 141, p. 125800, ago. 2020. DOI: <https://doi.org/10.1016/j.zool.2020.125800>.

LAHMIRI, Salim; DAWSON, Debra Ann; SHMUEL, Amir. Performance of machine learning methods in diagnosing Parkinson's disease based on dysphonia measures. **Biomedical Engineering Letters**, v. 8, n. 1, p. 29–39, 12 fev. 2018. DOI: <https://doi.org/10.1007/s13534-017-0051-2>.

LE BOEDEC, Kevin. Sensitivity and specificity of normality tests and consequences on reference interval accuracy at small sample size: a computer-simulation study. **Veterinary Clinical Pathology**, v. 45, n. 4, p. 648–656, dez. 2016. DOI: <https://doi.org/10.1111/vcp.12390>.

LEVIN, Johannes *et al.* Objective measurement of muscle rigidity in Parkinsonian patients treated with subthalamic stimulation. **Movement Disorders**, v. 24, n. 1, p. 57–63, 15 jan. 2009. DOI: <https://doi.org/10.1002/mds.22291>.

LI, Wendan *et al.* Recognition of Freezing of Gait in Parkinson's Disease Based on Machine Vision. **Frontiers in Aging Neuroscience**, v. 14, 14 jul. 2022. DOI: <https://doi.org/10.3389/fnagi.2022.921081>.

MAGALHÃES, Francisco *et al.* Teorias causais, sintomas motores, sintomas não-motores, diagnóstico e tratamento da Doença de Parkinson: uma revisão bibliográfica. **Research, Society and Development**, v. 11, n. 7, p. 1–15, 17 maio 2022. DOI: <http://dx.doi.org/10.33448/rsd-v11i7.29762>.

MAK, Margaret K. Y.; WONG, Eric C. Y.; HUI-CHAN, Christina W. Y. Quantitative measurement of trunk rigidity in parkinsonian patients. **Journal of Neurology**, v. 254, n. 2, p. 202–209, 2 fev. 2007. DOI: <https://doi.org/10.1007/s00415-006-0327-4>.

MARSILI, Luca *et al.* Bradykinesia in Neurodegenerative Disorders: A Blinded Video Analysis of Pathology-Proven Cases. **Movement Disorders**, v. 38, n. 3, p. 496–501, 27 mar. 2023. DOI: <https://doi.org/10.1002/mds.29330>.

MARSLAND, Stephen. **Machine learning: an algorithmic perspective**. 2. ed. New York: CRC, 2015, ISBN: 9780429102509, 1 e-book (457 p.). DOI: <https://doi.org/10.1201/b17476>.

MASSANO, João; BHATIA, Kailash P. Clinical approach to Parkinson's disease: Features, diagnosis, and principles of management. **Cold Spring Harbor Perspectives in Medicine**, v. 2, n. 6, 2012. DOI: <https://doi.org/10.1101/cshperspect.a008870>.

MATHIS, Alexander *et al.* DeepLabCut: markerless pose estimation of user-defined body parts with deep learning. **Nature Neuroscience**, v. 21, n. 9, p. 1281–1289, 1 set. 2018. DOI: <https://doi.org/10.1038/s41593-018-0209-y>.

MATLAB. THE MATHWORKS INC. MathWorks Inc. MATLAB. Natick: The MathWorks Inc, 2023. Disponível em: www.mathworks.com. Acesso em: 29 ago. 2025

MCKINNEY, Wes. **Python for Data Analysis: Data Wrangling with pandas, NumPy, and Jupyter**. 2nd. ed. Sebastopol: O'Reilly Media, 2017, 550 p.

MEDEIROS, Tony Alexandre *et al.* Classification of 1p/19q Status in Low-Grade Gliomas: Experiments with Radiomic Features and Ensemble-Based Machine Learning Methods. **Brazilian Archives of Biology and Technology**, v. 66, 2023. DOI: <https://doi.org/10.1590/1678-4324-2023230002>.

MEIGAL, Alexander Y. *et al.* Non-Linear EMG Parameters for Differential and Early Diagnostics of Parkinson's Disease. **Frontiers in Neurology**, v. 4, 2013. DOI: <https://doi.org/10.3389/fneur.2013.00135>.

MICROSOFT CORPORATION. **Visual Studio Code**. Redmond, 2025. Disponível em: <https://code.visualstudio.com/>. Acesso em: 29 ago. 2025

MITSUKANE, Masahiro *et al.* Immediate Effects of Repetitive Wrist Extension on Grip Strength in Patients With Distal Radial Fracture. **Archives of Physical Medicine and Rehabilitation**, v. 96, n. 5, p. 862–868, maio 2015. DOI: <https://doi.org/10.1016/j.apmr.2014.09.024>.

MOEZ ALI. PyCaret: **An open source, low-code machine learning library in Python**. Disponível em: <https://www.pycaret.org>. Acesso em: 28 jan. 2023.

MUKAKA, M. M. **Statistics Corner**: A guide to appropriate use of Correlation coefficient in medical research. **Malawi Medical Journal**. v. 24, n. 3, p. 69–71, set. 2012. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3576830/>. Acesso em: 5 jan. 2025.

NACHAR, Nadim. The Mann-Whitney U: A Test for Assessing Whether Two Independent Samples Come from the Same Distribution. **Tutorials in Quantitative Methods for Psychology**, v. 4, n. 1, p. 13–20, 1 mar. 2008. DOI: <https://doi.org/10.20982/tqmp.04.1.p013>.

NARANJO, Lizbeth *et al.* Addressing voice recording replications for Parkinson's disease detection. **Expert Systems with Applications**, v. 46, p. 286–292, mar. 2016. DOI: <https://doi.org/10.1007/s11517-016-1512-y>.

NAVITA *et al.* Gait-based Parkinson's disease diagnosis and severity classification using force sensors and machine learning. **Scientific Reports**, v. 15, n. 1, p. 328, 2 jan. 2025. DOI: <https://doi.org/10.1038/s41598-024-83357-9>.

NIELSEN, Jakob; LANDAUER, Thomas K. A mathematical model of the finding of usability problems. In: New York, USA: **ACM Press**, 1993. DOI: <https://doi.org/10.1145/169059.169166>.

NIETO-HIDALGO, Mario *et al.* Gait Analysis Using Computer Vision Based on Cloud Platform and Mobile Device. **Mobile Information Systems**, v. 2018, 2018. DOI: <https://doi.org/10.1155/2018/7381264>.

NOYCE, Alastair J. *et al.* Subtle motor disturbances in PREDICT-PD participants. **Journal of Neurology, Neurosurgery & Psychiatry**, v. 88, n. 3, p. 212–217, mar. 2017. DOI: <https://doi.org/10.1136/jnnp-2016-314524>.

NYHOLM, Dag. Duodopa® treatment for advanced Parkinson's disease: A review of efficacy and safety. **Parkinsonism & Related Disorders**, v. 18, n. 8, p. 916–929, set. 2012. DOI: <https://doi.org/10.1016/j.parkreldis.2012.06.022>.

ÖZSEVEN, Turgut; ÖZKORUCU, Zübeyir Şükrü. Optimization of Support Vector Machines for Prediction of Parkinson's Disease. **Measurement Science Review**, v. 23, n. 1, p. 1–10, 1 fev. 2023. DOI: <https://doi.org/10.2478/msr-2023-0001>.

PARKINSON, James. An Essay on the Shaking Palsy. **The Journal of Neuropsychiatry and Clinical Neurosciences**, v. 14, n. 2, p. 223–236, maio 2002. DOI: <https://doi.org/10.1176/jnp.14.2.223>.

PEREIRA, Clayton R. *et al.* A new computer vision-based approach to aid the diagnosis of Parkinson's disease. **Computer Methods and Programs in Biomedicine**, v. 136, p. 79–88, 1 nov. 2016. DOI: <https://doi.org/10.1016/j.cmpb.2016.08.005>.

PERERA, Thushara *et al.* A palm-worn device to quantify rigidity in Parkinson's disease. **Journal of Neuroscience Methods**, v. 317, n. February, p. 113–120, 2019. DOI: <https://doi.org/10.1016/j.jneumeth.2019.02.006>.

PERES, Luciano Brinck *et al.* Discrimination between healthy and patients with Parkinson's disease from hand resting activity using inertial measurement unit. **BioMedical Engineering OnLine**, v. 20, n. 1, 22 dez. 2021. DOI: <https://doi.org/10.1186/s12938-021-00888-2>.

PEREZ, CJ *et al.* Diagnosis and Tracking of Parkinson's Disease by using Automatically Extracted Acoustic Features. **Journal of Alzheimer's Disease & Parkinsonism**, v. 6, n. 5, 2016. DOI: <https://doi.org/10.4172/2161-0460.1000260>.

PROCHAZKA, Arthur *et al.* Measurement of rigidity in Parkinson's disease. **Movement Disorders**, v. 12, n. 1, p. 24–32, 4 jan. 1997. DOI: <https://doi.org/10.1002/mds.870120106>.

PUIG-DIVÍ, Albert *et al.* Validity and reliability of the Kinovea program in obtaining angles and distances using coordinates in 4 perspectives. **PLOS ONE**, v. 14, n. 6, p. e0216448, 5 jun. 2019. DOI: <https://doi.org/10.1371/journal.pone.0216448>.

RAIANO, Luigi *et al.* PDMeter: A Wrist Wearable Device for an at-Home Assessment of the Parkinson's Disease Rigidity. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 28, n. 6, p. 1325–1333, jun. 2020. DOI: <https://doi.org/10.1109/tnsre.2020.2987020>.

RASCHKA, Sebastian.; MIRJALILI, Vahid. **Python machine learning: machine learning and deep learning with Python, scikit-learn, and TensorFlow**. Birmingham: **Packt Publishing**, 2022. ISBN 978-1-78995-575-0.

RASHIDI, Hooman H. *et al.* Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods, Enhanced Reader. **Academic Pathology**, v. 6, 2019. DOI: <https://doi.org/10.1177/2374289519873088>.

REHMAN, Rana Zia Ur *et al.* Selecting Clinically Relevant Gait Characteristics for Classification of Early Parkinson's Disease: A Comprehensive Machine Learning Approach. **Scientific Reports**, v.9, n.1, p.1–12, 2019. DOI: <https://doi.org/10.1038/s41598-019-53656-7>.

REMESEIRO, Beatriz; BOLON-CANEDO, Veronica. A review of feature selection methods in medical applications. **Computers in Biology and Medicine**, v. 112, p. 103375, set. 2019. DOI: <https://doi.org/10.1016/j.combiomed.2019.103375>.

RIBEIRO, Caio. **Validação de uma órtese de punho instrumentada para avaliação da rigidez em pessoas com a doença de Parkinson**. 2023. 70 f. Dissertação (Mestrado em Engenharia Biomédica) — Programa de Pós-Graduação em Engenharia Biomédica, Universidade Federal de Uberlândia, Uberlândia, 2023. DOI: <http://doi.org/10.14393/ufu.di.2023.455>.

RIZZO, Giovanni *et al.* Accuracy of clinical diagnosis of Parkinson disease. **Neurology**, v. 86, n. 6, p. 566–576, 9 fev. 2016. DOI: <https://doi.org/10.1212/wnl.0000000000002350>.

ROSA, Artur Guerra; SILVA, Maiele Leandro da. RunData: an easy and intuitive online tool for statistical analyses. **Crop Breeding and Applied Biotechnology**, v. 20, n. 3, 2020. DOI: <https://doi.org/10.1590/1984-70332020v20n3s36>.

RUPPRECHTER, Samuel *et al.* A clinically interpretable computer-vision based method for quantifying gait in parkinson's disease. **Sensors**, v. 21, n. 16, 2 ago. 2021. DOI: <https://doi.org/10.3390/s21165437>.

SAEED, Adnan *et al.* Improving the Imbalanced Data Accuracy Using CNN and ReLU. **IETI Transactions on Data Analysis and Forecasting (iTDAF)**, v. 2, n. 3, p. 50–58, 18 out. 2024. DOI: <https://doi.org/10.3991/itdaf.v2i3.51013>.

SCHOBER, Patrick; SCHWARTE, Lothar A. Correlation coefficients: Appropriate use and interpretation. **Anesthesia and Analgesia**, v. 126, n. 5, p. 1763–1768, 1 maio 2018. DOI: <https://doi.org/10.1213/ane.00000000000002864>.

SEPEHRI, Behrooz *et al.* Quantification of Rigidity in Parkinson's Disease. **Annals of Biomedical Engineering**, v. 35, n. 12, 14 nov. 2007. DOI: <https://doi.org/10.1007/s10439-007-9379-6>.

SHAFI, Gowher. Object Tracking Using HSV Values and OpenCV. **International Journal for Research in Applied Science and Engineering Technology**, v. 9, n. 12, p. 594–599, 31 dez. 2021. DOI: <https://doi.org/10.22214/ijraset.2021.39238>.

SHAIK, Khamar Basha *et al.* Comparative Study of Skin Color Detection and Segmentation in HSV and YCbCr Color Space. **Procedia Computer Science**, v. 57, p. 41–48, 2015. DOI: <https://doi.org/10.1016/j.procs.2015.07.362>.

SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality (Complete Samples). **Biometrika**, v. 52, n. 3/4, p. 591, dez. 1965. DOI: <https://doi.org/10.2307/2333709>.

SICA, Marco *et al.* Continuous home monitoring of Parkinson's disease using inertial sensors: A systematic review. **PLOs ONE**, Public Library of Science, 1 fev. 2021. DOI: <https://doi.org/10.1371/journal.pone.0246528>.

SIGCHA, Luis *et al.* Deep learning and wearable sensors for the diagnosis and monitoring of Parkinson's disease: A systematic review. **Expert Systems with Applications**, v. 229, p. 120541, nov. 2023. DOI: <https://doi.org/10.1016/j.eswa.2023.120541>.

SILVA, D. H. da; RIBEIRO, C. T.; PEREIRA, A. A. Um estudo sobre o uso de modelos de Machine Learning para o diagnóstico da Doença de Parkinson por meio da análise de voz de pacientes. In: **Zenodo**, dez. 2022. DOI: <https://doi.org/10.5281/zenodo.7490097>.

SILVA, Daniel Hilário da *et al.* Application of Open-Source, Low-Code Machine-Learning Library in Python to Diagnose Parkinson's Disease Using Voice Signal Features. **Brazilian Archives of Biology and Technology**, v. 68, 2025a. DOI: <https://doi.org/10.1590/1678-4324-2025230860>.

SILVA, Daniel Hilário da *et al.* Exploring Essential Acoustic Features for Early Parkinson's Disease Classification: A Machine Learning Study. **International Journal of Online and Biomedical Engineering (iJOE)**, v. 21, n. 02, p. 98–120, 17 fev. 2025b. DOI: <https://doi.org/10.3991/ijoe.v21i02.50503>.

SON, Heesook; PARK, Won Seok; KIM, Hyerang. Mobility monitoring using smart technologies for Parkinson's disease in free-living environment. **Collegian**, v. 25, n. 5, p. 549–560, 1 out. 2018. DOI: <https://doi.org/10.1016/j.colegn.2017.11.005>.

SOTO, Angel *et al.* Gait Modelling of People with Parkinson's Disease. In: **IEEE**, 13 out. 2020. DOI: <https://doi.org/10.1109/ANDESCON50619.2020.9272181>.

STEPHENSON, Diane *et al.* The Qualification of an Enrichment Biomarker for Clinical Trials Targeting Early Stages of Parkinson's Disease. **Journal of Parkinson's Disease**, IOS Press, 2019. DOI: <https://doi.org/10.3233/jpd-191648>.

STUDENT. The Probable Error of a Mean. *Biometrika*, v. 6, n. 1, p. 1, mar. 1908. DOI: <https://doi.org/10.2307/2331554>.

SUPPA, Antonio *et al.* Voice in Parkinson's Disease: A Machine Learning Study. **Frontiers in Neurology**, v. 13, 15 fev. 2022. DOI: <https://doi.org/10.3389/fneur.2022.831428>.

SUTHAHARAN, Shan. Machine Learning Models and Algorithms for Big Data Classification. 1. ed. Boston, MA: **Springer**, 2016. v. 36. DOI: <https://doi.org/10.1007/978-1-4899-7641-3>.

TAMÁS, Gertrúd *et al.* Effect of subthalamic stimulation on distal and proximal upper limb movements in Parkinson's disease. **Brain Research**, v. 1648, p. 438–444, out. 2016. DOI: <https://doi.org/10.1016/j.brainres.2016.08.019>.

TANNER, C. M.; GOLDMAN, S. M. Epidemiology of Parkinson's Disease. **Neurologic Clinics**, v. 14, n. 2, p. 317–335, 1 maio 1996. DOI: [https://doi.org/10.1016/s0733-8619\(05\)70259-0](https://doi.org/10.1016/s0733-8619(05)70259-0).

TESKEY, Wesley J. E.; ELHABIBY, Mohamed; EL-SHEIMY, Naser. Inertial Sensing to Determine Movement Disorder Motion Present before and after Treatment. **Sensors**, v. 12, n. 3, p. 3512–3527, 12 mar. 2012. DOI: <https://doi.org/10.3390/s120303512>.

TOLIOS, Giannis. Simplifying Machine Learning with PyCaret A Low-code Approach for Beginners and Experts!. 1. ed. [S.l.]: Leanpub, 2022. v. 1

TOUGUI, Ilias; JILBAB, Abdelilah; MHAMDI, Jamal El. Machine Learning Smart System for Parkinson Disease Classification Using the Voice as a Biomarker. **Healthcare Informatics Research**, v. 28, n. 3, p. 210–221, 31 jul. 2022. DOI: <https://doi.org/10.4258/hir.2022.28.3.210>.

TSANAS, Athanasios *et al.* Nonlinear speech analysis algorithms mapped to a standard metric achieve clinically useful quantification of average Parkinson's disease symptom severity. **Journal of The Royal Society Interface**, v. 8, n. 59, p. 842–855, 6 jun. 2011. DOI: <https://doi.org/10.1098/rsif.2010.0456>.

VABALAS, Andrius *et al.* Machine learning algorithm validation with a limited sample size. *PLOS ONE*, v. 14, n. 11, p. e0224365, 7 nov. 2019. DOI: <https://doi.org/10.1371/journal.pone.0224365>.

VARALAKSHMI, P. *et al.* Diagnosis of Parkinson's disease from hand drawing utilizing hybrid models. *Parkinsonism and Related Disorders*, v. 105, p. 24–31, 1 dez. 2022. DOI: <https://doi.org/10.1016/j.parkreldis.2022.10.020>.

VIEIRA, Sônia. **Análise de Variância: Anova**. 1a ed. São Paulo: Atlas, 2006. ISBN 978-8522443031.

VIGNOUD, Gaëtan *et al.* Video-based automated analysis of MDS-UPDRS III parameters in Parkinson disease. [*S.d.*]. DOI: <https://doi.org/10.3233/jpd-223445>

VIRZI, Robert A. Refining the Test Phase of Usability Evaluation: How Many Subjects Is Enough? *Human Factors: The Journal of the Human Factors and Ergonomics Society*, v. 34, n. 4, p. 457–468, 23 ago. 1992. DOI: <https://doi.org/10.1177/001872089203400407>.

WEN, Xin *et al.* The effects of physiotherapy treatments on dysphagia in Parkinson's disease: A systematic review of randomized controlled trials. **Brain Research Bulletin**, v. 188, p. 59–66, out. 2022. DOI: <https://doi.org/10.1016/j.brainresbull.2022.07.016>.

WILLIAMS, Stefan *et al.* The discerning eye of computer vision: Can it measure Parkinson's finger tap bradykinesia? **Journal of the Neurological Sciences**, v. 416, 15 set. 2020. DOI: <https://doi.org/10.1016/j.jns.2020.117003>.

YASAR, A. *et al.* Classification of Parkinson disease data with artificial neural networks. **IOP Conference Series: Materials Science and Engineering**, v. 675, n. 1, p. 012031, 1 nov. 2019. DOI: <https://doi.org/10.1088/1757-899X/675/1/012031>.