

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA

VIVIANE DA CONCEIÇÃO LIMA

**Avaliação de desenhos senoidais de indivíduos com a doença de
Parkinson utilizando acelerometria**

Uberlândia

2022

VIVIANE DA CONCEIÇÃO LIMA

**Avaliação de desenhos senoidais de indivíduos com a doença de
Parkinson utilizando acelerometria**

Trabalho de Conclusão de Curso apresentado à
Faculdade de Engenharia Elétrica da
Universidade Federal de Uberlândia como
requisito parcial para obtenção do título de
bacharel em Engenharia Biomédica.

Orientador: Prof. Adriano de Oliveira Andrade,
PhD

Uberlândia

2022

VIVIANE DA CONCEIÇÃO LIMA

**Avaliação de desenhos senoidais de indivíduos com a doença de
Parkinson utilizando acelerometria**

Trabalho de Conclusão de Curso apresentado à
Faculdade de Engenharia Elétrica da
Universidade Federal de Uberlândia como
requisito parcial para obtenção do título de
bacharel em Engenharia Biomédica.

Uberlândia, 15/02/2022

Banca Examinadora:

Adriano de Oliveira Andrade – FEELT

Adriano Alves Pereira – FEELT

Amanda Gomes Rabelo – FEELT (Doutoranda no COPEL)

Dedico este trabalho à minha família, amigos e a todos que me apoiaram ao longo dessa jornada.

AGRADECIMENTOS

Agradeço primeiramente a Deus pelo dom da vida, por todas as bênçãos que já recebi e por todos os obstáculos que me fizeram amadurecer e evoluir.

A minha família, em especial as minhas irmãs Vanessa e Valdiane, por sempre me incentivarem e serem meus exemplos de força e coragem.

Ao meu namorado Lucas por todo apoio, incentivo e escuta ao longo dessa jornada.

Ao meu orientador, Adriano O. Andrade, por todos os ensinamentos e por ter despertado em mim a paixão pela análise de dados, além de ser um exemplo de entusiasmo e amor pelo que faz.

Aos meus professores que compartilharam seus conhecimentos e que foram essenciais na minha formação.

Aos meus amigos que me acompanharam ao longo dessa caminhada, compartilhando dos momentos de luta, superações e alegria e que permanecem comigo até hoje.

Agradeço à equipe do NIATS – Núcleo de Inovação e Avaliação Tecnológica em Saúde, que sempre incentivaram minha pesquisa, especialmente à Amanda Rabelo que me aconselhou e acompanhou de perto nos últimos anos.

Agradeço a todos os membros, colaboradores e pacientes da Associação Parkinson do Triângulo por sempre nos receberem com amor.

Também agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelas bolsas concedidas durante os anos do curso.

Por fim, também sou grata a mim mesma por não ter desistido diante das provas e por ter acreditado que um dia chegaríamos aqui.

Obrigada.

“Faça o teu melhor na condição que você tem,
enquanto não tem condições melhores, para fazer
melhor ainda”

Mário Sérgio Cortella.

RESUMO

A doença de Parkinson (DP) é marcada por tremor, rigidez, bradicinesia, entre outros aspectos. Esses sintomas comprometem as habilidades motoras, realizadas principalmente pelas mãos e dedos. Atualmente, uma das medidas mais utilizadas pelos profissionais da saúde é a aplicação de escalas clínicas que dependem de análise subjetiva. De forma a contribuir para a avaliação motora na DP, este trabalho teve como objetivo extrair informações de sensores sinais inerciais para avaliar quantitativamente o desempenho motor fino de pessoas com a DP. Para isso, o estudo contou com dois grupos, um de pessoas hígdas (GC) e outro com a DP (GP), que apresentavam tremor visível na mão ocasionado pela doença. Todos os voluntários tiveram sensores inercias posicionados sobre o dorso da mão. Os sinais foram coletados durante as tarefas de desenhar uma senóide com e sem o apoio visual de um contorno impresso em uma folha de papel. Duas características foram estimadas do correlograma obtido pela aplicação da função autocorrelação (FAC) sobre os sinais coletados: (i) a área normalizada sob a curva (**AuC**); (ii) a diferença entre picos e vales do correlograma de referência em relação ao correlograma estimado dos sinais coletados (**vmm**). Essas características permitiram a discriminação entre os padrões de desenho dos grupos avaliados. Para a atividade de contornar a senóide, o resultado obtido foi GC (**vmm** = 0,156 ± 0,059, **AuC** = 0,211 ± 0,032) e GP (**vmm** = 0,246 ± 0,085, **AuC** = 0,181 ± 0,036). Após a verificação da normalidade (Shapiro-Wilk, $p > 0,05$), o teste t foi aplicado para confirmar diferenças significativas entre os grupos ($p < 0,05$). O tamanho do efeito d de Cohen ($p < 0,05$) foi grande (0.903) para **AuC** e para **vmm** (1,238). Os resultados para a tarefa de desenhar a senóide livremente para o grupo GC foram (**vmm** = 0,261 ± 0,089, **AuC** = 0,186 ± 0,031) e para o grupo GP (**vmm** = 0,333 ± 0,086, **AuC** = 0,135 ± 0,041). O teste de Wilcoxon-Mann-Whitney foi aplicado para **vmm** e o teste t para **AuC**. Ambos os testes confirmaram diferenças significativas entre os grupos ($p < 0,05$). O tamanho do efeito foi grande para as duas características: δ de Cliff (0,486) e d de Cohen (1,366). Com isso, foi possível quantificar o desempenho motor dos voluntários e constatar que as pessoas com a DP tiveram um comprometimento da performance motora durante a realização da tarefa proposta. Este estudo comprovou que a avaliação de padrões senoidais por meio do correlograma de sinais inerciais é um método simples e prático para a quantificação do desempenho motor de pessoas com a DP.

Palavras-chave: Doença de Parkinson. Desempenho Motor. Função Autocorrelação. Acelerômetro. Desenho senoidal.

ABSTRACT

Tremor, stiffness, and bradykinesia are all symptoms of Parkinson's disease (PD). These symptoms impair motor skills, which are primarily performed by the hands and fingers. Currently, one of the most common measures used by health professionals is the use of clinical scales that rely on subjective analysis. This study aimed to extract information from inertial sensors in order to quantitatively evaluate the fine motor performance of people with Parkinson's disease. The study included two groups: one of healthy people (CG) and one of people with Parkinson's disease (PG) who had visible tremors in their hands as a result of the disease. Inertial sensors were placed on the back of each volunteer's hand. These signals were collected while participants were drawing a sinusoidal pattern with and without the aid of a printed outline on a piece of paper. The normalized area under the curve (AuC) and the difference between peaks and valleys of the reference correlogram in relation to the estimated correlogram of the collected signals were estimated from the correlogram obtained by applying the autocorrelation function (ACF) on the collected signals (v_{mm}). These characteristics allowed discrimination between the design patterns of CG and PG. For the activity of contouring the sinusoid, the obtained result was ($v_{mm} = 0.156 \pm 0.059$, $AuC = 0.211 \pm 0.032$) for GC and ($v_{mm} = 0.246 \pm 0.085$, $AuC = 0.181 \pm 0.036$) for PG. After normality verification (Shapiro-Wilk, $p > 0.05$), the *t-test* was applied to confirm significant differences between the groups ($p < 0.05$). Cohen's d-effect size ($p < 0.05$) was large (0.903) for AuC and v_{mm} (1.238). The results for the task of drawing the sinusoid freely for GC were ($v_{mm} = 0.261 \pm 0.089$, $AuC = 0.186 \pm 0.031$) and for PG ($v_{mm} = 0.333 \pm 0.086$, $AuC = 0.135 \pm 0.041$). The Wilcoxon-Mann-Whitney test was applied to v_{mm} and the *t* test to AuC. Both tests confirmed significant differences between groups ($p < 0.05$). The size of the effect was large for the two characteristics: δ cliff (0.486) and d-Cohen (1.366). This allowed researchers to quantify the volunteers' motor performance and confirm that people with Parkinson's disease had poorer motor performance when completing the tasks. The evaluation of sine patterns using a correlogram estimated from inertial signals proved to be a simple and practical method for quantifying the motor performance of people with Parkinson's disease in this study.

Keywords: Parkinson's Disease. Motor Performance. Autocorrelation Function. Accelerometer. Sinusoidal pattern.

LISTA DE ILUSTRAÇÕES

Figura 1 - Dispositivo TREMSSEN utilizado durante a coleta de dados.....	23
Figura 2 - Etapas utilizadas durante o processamento dos dados.....	23
Figura 3 - Janelamento das regiões de interesse.....	24
Figura 4 - Efeito de sub-amostragem no sinal.....	25
Figura 5 - Sinal com aspecto suave devido a reamostragem em 300 Hz	25
Figura 6 - Remoção de tendências lineares e não lineares. (a) Sinal sem remoção de tendências. (b) Sinal com tendências removidas	26
Figura 7 - Aplicação da função Loess. (a) Sinal sem suavização. (b) Sinal suavizado.....	28
Figura 8 - Correlograma do sinal de referência mostrando os valores de AuC, e os máximos e mínimos locais. Lag é o atraso de tempo discreto.	29
Figura 9: Correlogramas estimados para o grupo controle.....	30
Figura 10: Correlogramas estimados para o grupo GP. Lag é o atraso de tempo discreto.....	31
Figura 11 - Correlogramas estimados para o grupo GC para o desenho livre. Lag é o atraso de tempo discreto.	33
Figura 12: Correlogramas estimados para o grupo GP para o desenho livre. Lag é o atraso de tempo discreto.	34

LISTA DE TABELAS

Tabela 1 - Critérios clínicos para o diagnóstico da doença de Parkinson.	16
Tabela 2 - Níveis do tamanho do efeito do d de Cohen	21
Tabela 3 - Interpretação do tamanho do efeito do δ de Cliff.	22
Tabela 4 - Média e desvio padrão para v_{mm} e AuC de cada participante. VC e VP são rótulos que identificam os indivíduos dos grupos GC e GP, respectivamente.	31
Tabela 5 - Resultados do teste t e o tamanho do efeito para cada parâmetro.	32
Tabela 6 - Média e desvio padrão para v_{mm} e AuC para o desenho livre de cada participante. VC e VP são rótulos que identificam os indivíduos dos grupos GC e GP, respectivamente. ...	34
Tabela 7 - Resultados dos testes de diferença estatística e tamanho de efeito para cada parâmetro	35

LISTA DE ABREVIATURAS E SIGLAS

DP	Doença de Parkinson
FAC	Função Autocorrelação
GC	Grupo Controle
GP	Grupo Parkinson
UPDRS	Escala Unificada de Avaliação da Doença de Parkinson
PDQ-39	Questionário de Atividade de Parkinson
PAS	Escala de Atividade de Parkinson
PSN	Questionário de Qualidade de Vida da Doença de Parkinson
IMU	Inertial Measurement Units
WMW	Wilcoxon-Mann-Whitney
TREMSEN	Precise Tremor Sensing Technology
FCC	Função de Correlação Cruzada

SUMÁRIO

1	INTRODUÇÃO.....	12
1.1	Formulação do Problema.....	12
1.2	Objetivos.....	12
1.2.1	Objetivo Geral	12
1.2.2	Objetivos Específicos	12
1.3	Relevância da Pesquisa.....	13
1.4	Estrutura do Trabalho	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	Doença de Parkinson	14
2.2	Sintomas Motores	14
2.3	Diagnóstico e Avaliação da Doença de Parkinson	16
2.4	Sensores Inerciais.....	18
2.5	Função Autocorrelação	18
2.6	Testes Estatísticos	19
2.6.1	Teste de Shapiro-Wilk	19
2.6.2	Teste t.....	19
2.6.3	Teste de Wilcoxon–Mann–Whitney	20
2.6.4	d de Cohen	20
2.6.5	Delta (δ) de Cliff.....	21
3	METODOLOGIA.....	22
3.1	Descrição da base de dados.....	22
3.2	Etapas de Processamento	23
4	RESULTADOS	30
5	DISCUSSÃO.....	35
6	CONCLUSÃO.....	37
7	REFERÊNCIAS.....	38

1 INTRODUÇÃO

1.1 Formulação do Problema

Este trabalho está focado na avaliação do desempenho motor fino de pessoas com a doença de Parkinson (DP) ao realizarem uma tarefa manual. A coordenação motora fina pode ser caracterizada como aquela que requer um movimento pequeno, com pouca força e alta precisão ou velocidade, sendo executada principalmente pelas mãos ou pés (MEINEL, 1984).

As flutuações e disfunções motoras provocadas pela DP comprometem a coordenação motora fina, prejudicando o desenvolvimento de atividades do cotidiano, como carregar objetos e cuidar da higiene pessoal (ANTES e colab., 2009). No início da doença é possível normalizar a função motora quase completamente, por meio de terapias avançadas, mas à medida que a doença progride ocorre uma degradação do controle motor (MEMEDI e colab., 2015). E, apesar de muitos avanços tecnológicos, o diagnóstico da doença é essencialmente clínico, tornando-o por vezes muito demorado, o que inviabiliza o tratamento precoce.

Tendo em vista a necessidade de se obter parâmetros objetivos, com potencial para auxiliar no acompanhamento da evolução da doença, foi desenvolvido um algoritmo para processar e analisar sinais de acelerômetros, coletados durante a realização de desenhos de senóides, que avaliam o desempenho motor de pessoas com a DP. A principal hipótese do estudo é que os recursos extraídos da função autocorrelação (FAC) podem ser usados para avaliar e comparar o desempenho motor de pessoas com a doença de Parkinson e de indivíduos hígidos.

1.2 Objetivos

1.2.1 Objetivo Geral

Este trabalho teve como objetivo principal avaliar quantitativamente o desempenho motor fino de indivíduos hígidos e com a doença de Parkinson, por meio da aplicação de ferramentas de processamento de sinais inerciais.

1.2.2 Objetivos Específicos

Com o intuito de alcançar o objetivo principal definiu-se os seguintes objetivos específicos:

- Estabelecer as etapas de processamento necessárias;
- Selecionar o eixo que melhor representava o movimento realizado na tarefa;
- Determinar as características a serem extraídas do correlograma;
- Selecionar os métodos estatísticos para análise e comparação das características.

1.3 Relevância da Pesquisa

A doença de Parkinson é uma desordem neurodegenerativa com sintomas motores progressivos (DHALL e KREITZMAN, 2016), e que afeta aproximadamente 3% da população com mais de 65 anos de idade (PATEL e colab., 2009). Em 2018, o Brasil já possuía cerca de 20 milhões de idosos e até 2050 a expectativa é de 64 milhões de pessoas nessa faixa etária (DIAS e PAIS-RIBEIRO, 2018), ou seja, cerca de 1,9 milhões de idosos com a DP.

Apesar dos altos números, o diagnóstico da doença ainda é puramente clínico, não havendo nenhum exame, teste quantitativo ou biomarcador capaz de indicar o diagnóstico da doença, bem como a evolução do quadro clínico e motor do indivíduo (ANDRADE e colab., 2017). Com esse cenário, as possibilidades de um tratamento precoce são prejudicadas, já que o diagnóstico de alguns indivíduos pode levar de 5 a 10 anos (SOUSA, Lucas Resende e colab., 2021).

Com isso, os gastos econômicos relacionados a DP tendem a se elevar, visto que o custo com a hospitalização, medicamentos e reabilitação aumentam com o agravamento dos sintomas provocado pela progressão da doença (DOS SANTOS e DA SILVA, 2020). Segundo o estudo de CARVALHO e colab. (2021), realizado em Minas Gerais entre 2010 e 2017, os gastos brutos com medicamentos antiparkinsonianos tiveram um aumento de 305,3%, passando de R\$ 1,9 milhões em 2010 para R\$ 7,7 milhões em 2017.

Diante disso, o número de pesquisas interessadas no monitoramento dos sintomas motores e características que discriminem os indivíduos com a DP têm aumentado. Os estudos envolvem propostas com diferentes abordagens como sensores resistivos (JABLONSKI e colab., 2018), variáveis biomecânicas (SOUSA, Lucas Resende e colab., 2021) e utilização de redes neurais (KIM e colab., 2018).

1.4 Estrutura do Trabalho

Essa dissertação é composta pelos seguintes itens: introdução, fundamentação teórica, metodologia, resultados, discussão e conclusões. O volume da dissertação é de 56 páginas, nas quais são apresentadas: 12 figuras e 7 tabelas.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Doença de Parkinson

Em 1817, James Parkinson, em *An Essay On The Shaking Palsy* descreveu a doença de Parkinson como hoje a conhecemos, fazendo relatos sobre o tremor, a postura e a marcha (LIMONGI, 2001). No entanto, existem descrições dos sintomas da doença, como distúrbios na fala, festinação e movimentos involuntários, em documentos mais antigos (STERN, 1989).

A doença de Parkinson é uma desordem neurodegenerativa com sintomas motores progressivos (DHALL e KREITZMAN, 2016), que provoca desordens nos movimentos devido à deficiência de dopamina, um neurotransmissor responsável pelo envio de mensagens as regiões do cérebro que controlam a coordenação motora. Sua causa ainda não é completamente conhecida, mas fatores genéticos e ambientais parecem contribuir para seu aparecimento (TEIVE, 2000).

A DP é caracterizada pela presença de bradicinesia e acinesia acompanhada por uma redução gradual da amplitude e velocidade da ação repetitiva (SAAVEDRA MORENO e colab., 2019) e pelo menos uma outra manifestação motora, como rigidez ou tremor (LEES e colab., 2009). Geralmente os primeiros sintomas não são perceptíveis e evoluem lentamente. Com o avançar da doença, os familiares e amigos são os primeiros a perceberem a lentidão nos movimentos, a perda de espontaneidade na expressão facial e a rigidez postural (LIMONGI, 2001).

Essa degeneração é ocasionada pela formação dos corpos de Lewy que é encontrada em várias áreas encefálicas (KALINKE, 2017). Além disso, segundo BRAAK e colab. (2003), a DP apresenta uma evolução temporal e topográfica das lesões em diferentes regiões do cérebro e esse avanço pode ser descrito em 6 estágios. Nos estágios 1 e 2 ocorrem os distúrbios olfatórios e autonômicos, nos estágios 3 e 4 os distúrbios motores e, por fim, nos estágios 5 e 6, os distúrbios emocionais e cognitivos.

2.2 Sintomas Motores

Jean-Martin Charcot, considerado o primeiro professor de doenças do sistema nervoso no mundo, acrescentou várias contribuições pessoais na descrição do quadro clínico da doença de Parkinson, definindo a presença dos quatro sinais cardinais da doença, sendo eles o tremor, rigidez, lentidão do movimento (bradicinesia) e instabilidade postural (TEIVE, 1998).

O tremor é um movimento involuntário, oscilatório e rítmico, quase regular, produzido por contrações, simultâneas ou alternadas, de músculos antagonistas. O chamado tremor de repouso é aquele que ocorre quando o membro do corpo está relaxado ou na ausência da ação da gravidade, que pode desaparecer com o início de uma atividade motora voluntária. Sua frequência típica é de 3-6 Hz resultante da atividade alternante de músculos agonistas e antagonistas (MATTOS, 1998). No estágio inicial da DP, o tremor costuma ser unilateral, permanecendo assim por intervalos variáveis de tempo, mas, após certo período, pode atingir o lado oposto bem como a cabeça, mandíbula, queixo ou membros inferiores. Situações de estresse emocional ou a sensação de ser observado aumentam visivelmente a intensidade o tremor (LIMONGI, 2001).

Já rigidez é caracterizada por um aumento da resistência ao movimento passivo em toda sua extensão (SANT e colab., 2008). Isso acontece por causa do processo de ativação do músculo, que quando acionado para realizar determinado movimento, em condições normais, o cérebro inibe o conjunto de fibras musculares antagonistas a ele para facilitar esse movimento. No entanto, na doença de Parkinson, essa inibição não é feita de modo eficaz, pois alguns comandos cerebrais não chegam aos músculos corretamente, como consequência, os músculos tornam-se mais tensos e contraídos, e o paciente sente-se rígido e com pouca mobilidade (LIMONGI, 2001). Além de afetar os músculos, a rigidez, assim como a bradicinesia, também pode apresentar-se nos órgãos internos, como fígado, estômago e intestino, tornando-os mais lentos (BRAGA e colab., 2003).

A bradicinesia é caracterizada pela lentidão ao realizar movimentos (LIMONGI, 2001). Essa lentidão é causada pelo atraso na transmissão das instruções cerebrais necessárias para comandar as outras partes do corpo (DOS SANTOS STEIDL e colab., 2007) e pela carência de movimentos devido à redução de neurônios dopaminérgicos. Os movimentos que demandam maior precisão são mais afetados que aqueles de grande amplitude, ou seja, inicialmente o paciente percebe a dificuldade de usar ferramentas pequenas ou em realizar tarefas como abotoar roupas. As atividades repetitivas também são afetadas, tornando-se difícil, por exemplo, escovar os dentes (NUTT e WOOTEN, 2005). Com a progressão da doença esse sintoma tende a evoluir, diminuindo a amplitude dos movimentos e tornando-os cada vez mais escassos (CALAND, 2015).

A instabilidade postural ocorre devido à perda dos reflexos posturais e geralmente é uma manifestação dos estágios finais da DP, ocorrendo após o início de outras características clínicas (JANKOVIC, J, 2008). Essa condição favorece o aumento de quedas e, com o evoluir da doença, não permite que a pessoa com a doença de Parkinson possa se levantar, ou manter-se de pé, sem assistência (FREITAS e colab., 2006). Isso ocorre pela diminuição das reações de endireitamento, equilíbrio e extensão protetora causadas por esse sintoma (IKE, 2017). De acordo com JANKOVIC (2008), vários outros fatores também podem influenciar na ocorrência da instabilidade postural em pacientes com DP, como hipotensão ortostática, alterações sensoriais relacionadas à idade e a capacidade de integrar dados sensoriais visuais, vestibulares e proprioceptivos (cinestesia).

2.3 Diagnóstico e Avaliação da Doença de Parkinson

A confirmação definitiva da doença de Parkinson só é possível com um exame histológico *post mortem* somado ao provável diagnóstico clínico. Na avaliação clínica, o médico neurologista examina se o paciente apresenta alguns dos chamados sintomas motores cardinais (tremor de repouso, rigidez muscular, bradicinesia e alterações posturais) e também verifica se existe uma resposta positiva ao tratamento dopaminérgico (CALAND, 2015).

O diagnóstico da DP é baseado em critérios clínicos que se apoia na análise cuidadosa do histórico familiar do paciente e um exame físico minucioso, já que não existem exames de imagens, marcadores biológicos ou testes laboratoriais que confirme irrefutavelmente o diagnóstico da doença (MOREIRA e colab., 2007). Na tabela a seguir são apresentados os critérios clínicos utilizados para diagnosticar a DP.

Tabela 1 - Critérios clínicos para o diagnóstico da doença de Parkinson.

Doença de Parkinson clinicamente provável	Combinação de pelo menos dois sintomas/sinais cardinais (incluindo distúrbios dos reflexos posturais) e resposta ao uso de levodopa ou dopaminérgicos (ou ausência de tratamento adequado com levodopa ou dopaminérgicos)
Doença de Parkinson clinicamente definida	Qualquer combinação de três dos quatro sintomas/sinas cardinais e resposta ao uso de levodopa ou dopaminérgicos
Doença de Parkinson definitivamente comprovada	Presença de todos os critérios possíveis para o diagnóstico da doença de Parkinson e realização de autópsia

Fonte: Adaptado de (MOREIRA e colab., 2007; TAPIA-NÚÑEZ e CHANA-CUEVAS, 2004)

Ao longo do tempo foram criadas escalas para avaliar a DP (HELY e colab., 1993), que analisam desde a condição clínica geral, função motora e mental até a qualidade de vida dos pacientes. No entanto, a sua aplicação é determinada pelo profissional, que seleciona escalas que permitam uma tomada de decisão clínica compatível com seu local de trabalho, com as necessidades do paciente e com o meio em que ele vive, o que propicia resultados divergentes entre os especialistas.

De acordo com MELLO e BOTELHO (2010), as principais escalas para avaliação da doença de Parkinson são:

- Escala de Hoehn e Yahr Modificada: avalia a incapacidade dos indivíduos e é capaz de indicar o estado geral do paciente de forma rápida e prática;
- Escala Sydney: foi usada pela primeira vez em 1984 e se subdivide em 11 categorias, com um escore total de 89, sendo que quanto menor a pontuação, melhor a condição do paciente;
- Escala unificada de avaliação da doença de Parkinson (UPDRS): escala que avalia os sinais, sintomas e determinadas atividades dos pacientes por meio do autorrelato e da observação clínica;
- Questionário de doença de Parkinson (PDQ-39): escala específica para a DP e compreende 39 itens que podem ser respondidos com cinco opções diferentes de resposta. A pontuação varia de 0 (nenhum problema) a 100 (máximo nível de problema), portanto, uma baixa pontuação indica a percepção do indivíduo de uma melhor qualidade de vida.
- Escala de atividade de Parkinson (PAS): escala para caracterizar problemas funcionais de indivíduos que estão nos estágios moderado e severo da doença.
- Questionário de qualidade de vida da doença de Parkinson (PSN): avalia a qualidade de vida do paciente por meio do perfil de Saúde de Nottingham (PSN), um indicador simples e direto da percepção do indivíduo em relação à saúde física, emocional e social.

Apesar de serem métodos muito utilizados, essas escalas não informam características objetivas e em tempo real relacionadas às particularidades dos sintomas motores como amplitude e frequência, por exemplo. Consequentemente, a natureza subjetiva dessas escalas pode fornecer informações que variam de acordo com o avaliador, prejudicando o diagnóstico e o acompanhamento do tratamento dos pacientes com a DP (SILVA, Ana Paula Sousa Paixão Barroso Da, 2018).

2.4 Sensores Inerciais

As unidades de medição inercias (IMU - Inertial Measurement Units) vêm se tornando ferramentas muito úteis para aquisição de informações relacionadas ao movimento corporal. As IMUs já possuem inúmeras aplicações na área da saúde e esporte, onde são utilizadas para auxiliar na avaliação de postura, assimetria de movimentos, análise de marcha dentre outras (RODRIGUES, 2018).

As IMUs são usadas principalmente para medir velocidade, orientação e força gravitacional. Anteriormente, a IMU era composta por dois sensores: acelerômetro, usado para medir a aceleração inercial, e giroscópio, que mede a rotação angular. Posteriormente a IMU passou a ser composta por um outro tipo de sensor, o magnetômetro, que mede a direção magnética do rolamento podendo melhorar a leitura do giroscópio. Normalmente, os sensores possuem três graus de liberdade obtendo medições nos três eixos (x, y e z) (AHMAD e colab., 2013).

Os acelerômetros medem a aceleração linear $\left(g \text{ ou } \frac{m}{s^2}\right)$ em relação a um eixo de referência. A aceleração linear pode ser detectada por meio de um dispositivo eletromecânico baseado em um sistema massa/mola ou por meio do princípio piezoelétrico (SHAEFFER, 2013). Os giroscópios medem a velocidade angular ($^{\circ}/s$) e alguns sensores também utilizam o sistema eletromecânico massa/mola como princípio de funcionamento (FERREIRA, 2013). Já o sensor magnetômetro baseia-se no Efeito Hall para determinar a intensidade, direção e sentido de campos magnéticos (FERNÁNDEZ PINTO, 2010).

2.5 Função Autocorrelação

A função autocorrelação mede a regularidade de um sinal, ou seja, determina a similaridade de um sinal com ele mesmo atrasado no tempo (DE SOUZA, 2018). Por não ser influenciada pelas unidades de medida, a FAC é muito útil para comparar as propriedades básicas das séries temporais (FULLER, 2009), além de ser uma ferramenta relevante para avaliar a estacionariedade e a presença de periodicidade em sinais biomédicos (WISE, 1955).

A função autocorrelação de uma série temporal discreta, $x[n]$, cujo número total de amostras é igual a N , pode ser definida para o m -ésimo atraso como:

$$FAC(m) = \frac{1}{N} \sum_{n=1}^N x(n) \cdot x(n + m) \quad (1)$$

Além disso, a aplicação da FAC sobre uma série temporal gera um gráfico, chamado de correlograma, que possui limites de significância estatística. Quando as defasagens ultrapassam os limites, as autocorrelações são consideradas significativas, ou seja, diferente de zero (FRACARO, 2018). Desse modo, ao observar o correlograma, podemos indicar onde houve correlações relevantes e fazer análises sobre os padrões observados.

2.6 Testes Estatísticos

2.6.1 Teste de Shapiro-Wilk

O teste de Shapiro-Wilk é utilizado para verificar se um conjunto de dados segue uma distribuição normal. Através do cálculo da estatística W , testa-se a hipótese nula, para uma amostra aleatória, onde é possível verificar a normalidade (SHAPIRO e FRANCIA, 1972).

O valor de W pode ser calculado como mostrado em (2):

$$W = \frac{(\sum_{i=1}^n a_i x_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (2)$$

sendo x_i os valores da amostra ordenados e a_i uma constante calculada:

$$a_i = \frac{m^T V^{-1}}{c} \quad (3)$$

onde V é uma de matriz de covariância, m e C são vetores normalizados que podem ser obtidos em (4):

$$C = |V^{-1}m| \quad e \quad m = (m_1, m_2, m_3, \dots, m_i) \quad (4)$$

2.6.2 Teste t

O Teste t é um teste de hipótese que usa conceitos estatísticos para rejeitar ou não uma hipótese nula. Nesse método é realizado a comparação das médias de duas amostras específicas para verificar se elas são iguais ou diferentes, ou seja, se existe ou não diferença estatística entre ambas (SOUSA, Rodrigues De, 2018).

O Teste t recebe esse nome por ser baseado em valores t , ou seja, um valor padronizado que é calculado a partir de dados amostrais durante um teste de hipótese. O valor de t pode ser calculado conforme a mostrado em (5):

$$t = \frac{\bar{x} - \mu_0}{\frac{s}{\sqrt{n}}} \quad (5)$$

em que $\bar{x}$ é média da amostra, μ_0 média da população, s o desvio padrão amostral e n o tamanho da amostra. Se a hipótese nula for definida como $\bar{x} \leq \mu_0$ e a hipótese alternativa for $\bar{x} > \mu_0$, quanto maior o valor de t , maior o nível de confiança em rejeitar a hipótese nula.

Para aplicação do Teste t é necessário que as duas amostras sigam uma distribuição normal. Essa condição pode ser verificada pelo teste de Shapiro-Wilk, mostrado na seção 2.6.1

2.6.3 Teste de Wilcoxon–Mann–Whitney

O teste de Wilcoxon-Mann-Whitney (WMW) é regularmente usado para comparar as médias ou medianas de duas distribuições independentes, que não seguem uma distribuição normal (FAGERLAND e SANDVIK, 2009).

Ao contrário do teste t , que testa a igualdade das médias, o teste Wilcoxon-Mann-Whitney, ou teste U , testa a igualdade entre as medianas. O teste é baseado nos ranking dos valores obtidos ao combinar as duas amostras, para isso os valores são ordenados, do menor para o maior, independentemente de qual amostra tenha vindo, com isso é possível avaliar o grau de entrelaçamento dos dados dos dois grupos após a ordenação (SILVA, Pedro Giovâni Da e BOGONI, 2015).

O resultado da aplicação do teste é construído por meio da atribuição de U a cada um dos valores das duas amostras. O valor de U pode ser calculado da seguinte forma:

$$U_1 = n_1 n_2 + \frac{n_1(n_1+1)}{2} - R_1 \text{ e } U_2 = n_1 n_2 + \frac{n_2(n_2+1)}{2} - R_2 \quad (6)$$

onde n_1 e n_2 são os tamanhos das amostras 1 e 2, R_1 e R_2 é a soma dos postos de cada grupo, respectivamente.

Quando houver poucos empates ou nenhum empate, a estatística de teste será dada por (7) que corresponde ao mínimo entre U_1 e U_2 (SOUSA, Marcos Douglas Rodrigues De, 2018):

$$U = \min (U_1, U_2) \quad (7)$$

2.6.4 d de Cohen

O d de Cohen é uma medida de magnitude de efeito, que pode abranger grupos não-pareados ou pareados. Comumente, está associado ao teste t e pode ser calculado como mostrado a seguir (LAKENS, 2013):

$$d = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{(n-1)S_1^2 + (m-1)S_2^2}{n+m-2}}} \quad (8)$$

em que $\bar{X}$ representa a média do grupo 1, $\bar{Y}$ a média do grupo 2, S_1^2 e S_2^2 representam a variância amostral do grupo 1 e 2, respectivamente, e n e m representam o número de observações do grupo 1 e do grupo 2.

De acordo com os critério de (COHEN, 1988) o valor de d pode ser interpretado conforme mostrado na Tabela 2:

Tabela 2 - Níveis do tamanho do efeito do d de Cohen

Valor de $ d $	Tamanho do Efeito
0,2	Pequeno
0,5	Médio
0,8	Grande

Fonte: Adaptado de (BRYDGES, 2019)

2.6.5 Delta (δ) de Cliff

O Delta (δ) de Cliff é uma medida não paramétrica, geralmente relacionada ao teste U, que serve para quantificar o grau de diferença entre dois grupos independentes, que não atendem ao princípio da normalidade (SOUSA, Marcos Douglas Rodrigues De, 2018). De acordo com CLIFF (1996), o δ avalia a probabilidade de uma amostra aleatoriamente selecionada de um grupo ser maior do que uma amostra de outro grupo, também selecionada ao acaso, menos a probabilidade reversa.

O cálculo da estimativa do delta de Cliff é mostrado em (9):

$$\delta = \frac{\#(x_i > x_j) - \#(x_i < x_j)}{mn} \quad (9)$$

Sendo que, x_i e x_j representam os scores dos grupos x e y , respectivamente e n e m o número de observações de cada grupo. De acordo com (CLIFF, 1993), $\#$ representa o número de contagem.

O valor de δ também pode ser obtido como uma simples transformação da estatística U de Wilcoxon-Mann-Whitney (CLIFF, 1993):

$$\delta = \frac{2U}{mn} - 1 \quad (10)$$

onde, U representa o resultado da estatística de WMW e n e m o número de observações de cada grupo. O valor de δ pode variar de -1 a 1 e sua interpretação é dada na Tabela 3:

Tabela 3 - Interpretação do tamanho do efeito do δ de Cliff.

Valor de δ	Tamanho do Efeito
$< 0,147$	Insignificante
$< 0,33$	Pequeno
$< 0,474$	Médio
$> 0,474$	Grande

Fonte: (SOUZA, Marcos Douglas Rodrigues De, 2018)

3 METODOLOGIA

3.1 Descrição da base de dados

A base de dados utilizada é resultado de um estudo previamente desenvolvido (PAIXÃO e colab., 2018) que foi aprovado pelo Comitê de Ética da Universidade Federal de Uberlândia (CAAE: 65165416.4.0000.5152). Dessa base foram utilizados os sinais de dois grupos distintos, cada um com 12 voluntários. O grupo controle (GC) foi formado por indivíduos hígidos, enquanto o grupo (GP) incluiu pessoas com a doença de Parkinson que possuíam tremor visível no pulso e que estavam sob a influência de medicação antiparkinsoniana durante a coleta dos dados (PAIXÃO e colab., 2018).

Cada voluntário teve uma IMU, composta por acelerômetro, giroscópio e magnetômetro, tri axiais, colocada sob o dorso da mão para captura dos sinais durante a realização do movimento. De acordo com o protocolo de coleta, foi solicitado aos voluntários que desenhassem padrões senoidais, primeiro seguindo um desenho de referência de uma senoide de quatro picos e em seguida desenhando a figura livremente, usando um lápis preso ao dedo indicador. A tarefa foi realizada três vezes por cada participante com intervalos de 60 segundos, ou seja, ao finalizar o contorno da senoide e o desenho livre o voluntário realizava uma pausa de um minuto antes da próxima repetição.

Os dados da IMU foram coletados a 50 Hz por meio do Precise Tremor Sensing Technology (TREMSSEN) (Figura 1), patenteado pelo Instituto Nacional de Propriedade Intelectual - Brasil – (BR 10 2014 023282 6). Para a realização da análise e processamento foram selecionados apenas os sinais coletados pelo acelerômetro, já que esse sensor é capaz de medir as variações de aceleração durante a realização do movimento sendo possível assim mapear as características da trajetória realizada.

Figura 1 - Dispositivo TREMSEN utilizado durante a coleta de dados




Fonte: (SILVA, Ana Paula Sousa Paixão Barroso Da, 2018)

3.2 Etapas de Processamento

A análise dos dados foi feita no R-Studio (RSTUDIO TEAM, 2019) utilizando a linguagem R (R CORE TEAM, 2020). Além disso, também foi utilizada a biblioteca TREMSEN-Toolbox (DE OLIVEIRA ANDRADE, 2019), que é um conjunto de ferramentas desenvolvidas para o processamento de sinais coletados com o dispositivo TREMSEN, disponível em <https://github.com/NIATS-UFU/TREMSEN-Toolbox>.

Na Figura 2 são mostradas as etapas de processamento utilizadas na análise dos dados.

Figura 2 - Etapas utilizadas durante o processamento dos dados



Fonte: A autora

O “Sinal Acc” representa o sinal do acelerômetro em uma das coordenadas X, Y e Z. O carregamento dos dados para o R-Studio foi feito por meio da função *LoadTREMSENFile* (DE OLIVEIRA ANDRADE, 2019) a partir de um arquivo .txt salvo pelo equipamento TREMSEN após a coleta.


3.2.1 Janelamento

Durante a coleta, as tarefas de contornar o padrão senoidal e depois desenhá-lo livremente foram salvas em um mesmo arquivo. Diante disso, foi necessário separar os sinais correspondentes a cada atividade realizada para uma análise correta dos dados.

Assim, o objetivo desta etapa foi selecionar as regiões de interesse correspondente a cada movimento e separá-los em variáveis diferentes. O janelamento foi realizado sem sobreposição e o tamanho da janela foi definido por meio de uma coluna de pulsos formada de zero e um, presente no arquivo salvo pelo TREMSSEN. Esses pulsos foram gerados por um botão que o avaliador pressionava para demarcar o início e o fim de cada atividade, sendo que o número 1 era correspondente ao período de realização da tarefa e o 0 indicava o fim da atividade (PAIXÃO e colab., 2018). Também houve inspeção visual para verificar que as tarefas haviam sido separadas corretamente.

Na Figura 3 é mostrada a seleção das regiões de interesse de acordo com cada tarefa.

Figura 3 - Janelamento das regiões de interesse




Fonte: A autora

Na Figura 3 a amplitude do pulso de marcação, durante a plotagem do sinal, foi reduzida de 1 para 0,15, além disso também foram removidas as tendências lineares e não-lineares, que serão apresentadas na etapa 3.2.3, para melhor compreensão da imagem.

3.2.2 Reamostragem

Após a etapa de janelamento percebeu-se que o sinal apresentava características de sub-amostragem, fenômeno que ocorre quando há uma amostragem insuficiente de determinado elemento. Esse fato impede o aspecto suave entre cada amostra, como pode ser verificado na Figura 4, além de provocar perda de informações.


Figura 4 - Efeito de sub-amostragem no sinal



Fonte: A autora

A reamostragem dos sinais foi necessária, pois o sistema TREMSSEN possui uma taxa fixa de amostragem em 50 Hz. Para corrigir esse impasse, várias frequências foram testadas e a frequência de reamostragem de 300 Hz, que apresentou os melhores resultados, foi utilizada. A função *ResampleTremsenData* (DE OLIVEIRA ANDRADE, 2019), que usa uma interpolação cúbica por spline, foi empregada na resolução dessa questão. Os sinais reamostrados foram utilizados na etapa seguinte e o resultado dessa aplicação pode ser observado na Figura 5.

Figura 5 - Sinal com aspecto suave devido a reamostragem em 300 Hz




Fonte: A autora

3.2.3 Remover Tendências

Durante a coleta dos dados pode haver a contaminação do sinal com componentes de baixa frequência não relacionados ao tremor, causada por meio de variáveis como gravidade, movimentos da mão e antebraço que não correspondem a atividade proposta e interferência do campo magnético da Terra (NASIR HUSAIN e colab., 2016). Essas componentes de baixa frequência geram o que chamamos de tendências lineares e não lineares e quando não removidas podem provocar uma interpretação errônea dos dados.

Para remover essas tendências aplicou-se a função *Loess*, disponível no pacote R Statistics (R CORE TEAM, 2020) com suavização de 75%. O resultado dessa etapa pode ser verificado na Figura 6 a seguir.

Figura 6 - Remoção de tendências lineares e não lineares. (a) Sinal sem remoção de tendências. (b) Sinal com tendências removidas



Fonte: A autora

3.2.4 Remoção de Outliers

Os chamados outliers são valores atípicos, que apresentam um grande afastamento das demais amostras da série temporal. De acordo com testes realizados com o TREMSSEN, com o intuito de reproduzir o protocolo utilizado, compreendeu-se que o surgimento desses pontos distintos ocorreu por causa do movimento abrupto da mão no início e no final da tarefa experimental.

Os outliers presentes nos sinais foram eliminados usando interpolação linear para que não houvesse influência sobre os resultados da análise.

3.2.5 Seleção do melhor eixo

Até a etapa 3.2.4, o processamento dos dados foi feito sobre as três componentes do acelerômetro, X, Y e Z, pois até então não havia sido definido qual eixo teria descrito melhor o movimento da mão ao realizar o desenho.

Para selecionar o eixo que melhor capturou as características do movimento realizado por cada participante, aplicou-se a função de correlação cruzada (FCC), que é análoga à FAC (1), entre cada componente e um sinal de referência. A FCC mede o grau de similaridade entre duas series temporais em função de um atraso aplicado a um dos sinais.

Desse modo, a seleção do eixo foi baseada na identificação do maior nível de similaridade entre os sinais de cada repetição (uma para cada eixo) e o sinal de referência. Utilizamos como sinal de referência o sinal de uma senóide sintética, de quatro picos, definida por (11) com frequência de oscilação, f , de 0,22 Hz, frequência amostral, f_s , de 300 Hz e resolução temporal, em segundos, de $\frac{1}{f_s}$.


$$v_r(t) = \sin(2 \cdot \pi \cdot f \cdot t), \{t \in \mathbf{R}: 1 \leq t \leq 18,2\} \quad (11)$$

O sinal selecionado pela aplicação dessa etapa passou a ser utilizado nos passos seguintes do fluxo mostrado na Figura 2.

3.2.6 Suavização

Para eliminar os artefatos de alta frequência presentes no sinal, foi aplicado a função *Loess*, disponível em (NASIR HUSAIN e colab., 2016), com um nível de suavização de 15%. Esta estratégia evitou a necessidade de definir frequências de corte distintas para cada coleta realizada, caso fosse utilizado um filtro passa-baixa que geralmente é a estratégia utilizada. O resultado da aplicação dessa função pode ser visto na Figura 7:

Figura 7 - Aplicação da função Loess. (a) Sinal sem suavização. (b) Sinal suavizado



Fonte: A autora

3.2.7 Aplicação da Função Autocorrelação (FAC)

Ao longo dessa pesquisa, investigou-se muitas maneiras de quantificar a influência que os sintomas motores, provocados pela doença de Parkinson, causavam na realização da atividade descrita no protocolo.

Após estudos, a função autocorrelação foi selecionada, já que ela mede o grau de similaridade de um sinal com ele mesmo defasado no tempo e é capaz de avaliar a estacionaridade e a presença de periodicidade em sinais biomédicos. Assim, a função autocorrelação foi aplicada ao eixo do acelerômetro, com maior similaridade à senoide de referência, em cada uma das 3 repetições das tarefas realizadas pelos voluntários.

A estimativa da FAC gerou um correlograma para cada sinal processado. O correlograma é o gráfico que mostra as autocorrelações em diversas defasagens e que permite identificar se a série é aleatória ou se possui alguma tendência ou sazonalidade. Com a análise desse elemento, era esperado que por meio da FAC fosse possível encontrar diferenças na periodicidade dos sinais das pessoas do grupo GC e do grupo GP e com isso refletir sobre o desempenho motor de cada grupo.

3.2.8 Extração de Características


Após a aplicação da função autocorrelação, foram extraídas duas características dos correlogramas gerados. A primeira foi a área normalizada sob a curva (AuC) como mostrado em (12).

$$AuC = \frac{1}{N} \int_1^N FAC(m) dm \quad (12)$$

A segunda característica foi definida como sendo a média das diferenças entre os picos e vales correspondentes do correlograma de referência e o correlograma estimado, v_{mm} (13). A Figura 8 ilustra o correlograma de referência estimado a partir do sinal da senoide descrita em (11), onde Lag é o atraso de tempo discreto. Para o correlograma de referência o valor de AuC foi de 0,32.

Figura 8 - Correlograma do sinal de referência mostrando os valores de AuC , e os máximos e mínimos locais.

Lag é o atraso de tempo discreto.



Fonte: A autora

Os valores de máximos e mínimos locais do correlograma de referência, mostrados na Figura 8, foram organizados um vetor, V_{rr} :

$$V_{rr} = [-0.87, 0.75, -0.62, 0.50, -0.37, 0.25, -0.12].$$

O v_{mm} foi definido como em (13), no qual V_{cc} é o vetor de comprimento especificado pelo conjunto de máximo e mínimo local dos P correlogramas estimados e Z é o número total de picos e vales.

$$v_{mm} = \frac{1}{P} \sum_{i=1}^P V_{rr}^i - V_{cc}^i, \{i \in \mathbf{N}: 1 \leq i \leq Z\} \quad (13)$$

A partir dos valores estimados de AuC e v_{mm} testes estatísticos foram aplicados para investigar as características de cada grupo.

3.2.9 Análise Estatística

A média e o desvio padrão das características (AuC , v_{mm}) foram estimados para as três repetições de cada participante nas duas tarefas realizadas, o desenho livre e o contorno da


senoide. O teste Shapiro-Wilk ($p > 0,05$) foi aplicado para verificar a normalidade das variáveis e constatou-se que as amostras para o contorno do desenho seguiam uma distribuição normal, mas a amostra do grupo GC para o desenho livre da senoide não.

Desse modo, para o contorno da senoide, as diferenças estatísticas foram testadas pelo teste t ($p < 0,05$), já as diferenças estatísticas para as amostras da tarefa de desenhar a senoide livremente foram testadas pelo teste de Wilcoxon-Mann-Whitney ($w < 0,05$). Por fim, o tamanho do efeito foi estimado pelo d de Cohen ($p < 0,05$) para o teste t e para medir o tamanho do efeito do teste WMW foi utilizado o δ de Cliff ($p < 0,05$).

4 RESULTADOS


Após a aplicação da função autocorrelação, os correlogramas estimados para os voluntários dos grupos GC e GP, para a tarefa contorno da senoide, foram agrupados e os resultados obtidos podem ser encontrados nas Figuras 9 e 10. A Figura 9 mostra os correlogramas dos voluntários hígidos e a Figura 10 corresponde aos gráficos das pessoas com a doença de Parkinson.

Figura 9: Correlogramas estimados para o grupo controle



Fonte: A autora.

Figura 10: Correlogramas estimados para o grupo GP. Lag é o atraso de tempo discreto



Fonte: A autora.

Ao observarmos os correlogramas é possível notar que os gráficos para o grupo controle seguem uma padronização, entre os voluntários, se assemelhando ao correlograma de referência, tanto em número de picos quanto na forma de decaimento da amplitude. Já nos correlogramas do grupo com Parkinson, podemos observar uma heterogeneidade entre cada participante, apesar de alguns voluntários terem conseguido manter o padrão encontrado no correlograma de referência.

A Tabela 4 mostra a média e o desvio padrão das características estimadas para cada grupo.

Tabela 4 - Média e desvio padrão para v_{mm} e AuC de cada participante. VC e VP são rótulos que identificam os indivíduos dos grupos GC e GP, respectivamente.

Participante	v_{mm} (média±std)	AuC (média±std)
VC01	0,050 ± 0,029	0,267 ± 0,028
VC02	0,063 ± 0,028	0,270 ± 0,028

VC03	0,217 ± 0,060	0,196 ± 0,060
VC04	0,105 ± 0,050	0,191 ± 0,051
VC05	0,211 ± 0,136	0,174 ± 0,136
VC06	0,154 ± 0,068	0,209 ± 0,079
VC07	0,174 ± 0,150	0,203 ± 0,068
VC08	0,135 ± 0,078	0,220 ± 0,078
VC09	0,239 ± 0,148	0,167 ± 0,148
VC10	0,179 ± 0,116	0,219 ± 0,116
VC11	0,184 ± 0,046	0,200 ± 0,046
VC12	0,156 ± 0,043	0,222 ± 0,043
VP01	0,116 ± 0,012	0,224 ± 0,015
VP02	0,336 ± 0,041	0,139 ± 0,028
VP03	0,221 ± 0,081	0,180 ± 0,041
VP04	0,313 ± 0,062	0,152 ± 0,041
VP05	0,099 ± 0,044	0,255 ± 0,028
VP06	0,177 ± 0,070	0,203 ± 0,039
VP07	0,266 ± 0,133	0,188 ± 0,065
VP08	0,328 ± 0,046	0,149 ± 0,011
VP09	0,341 ± 0,069	0,143 ± 0,128
VP10	0,297 ± 0,014	0,163 ± 0,007
VP11	0,188 ± 0,019	0,207 ± 0,015
VP12	0,272 ± 0,074	0,167 ± 0,027

Fonte: A autora

Após a análise individual, calculou-se a média geral e o desvio padrão das características para cada grupo e o resultado obtido foi um $v_{mm} = 0,156 \pm 0,059$ e $AuC = 0,212 \pm 0,032$ para o CG, e $v_{mm} = 0,246 \pm 0,085$ e $AuC = 0,181 \pm 0,036$ para o grupo GP.

O teste Shapiro-wilk (RAZALI e WAH, 2011) confirmou a normalidade de ambas as variáveis para ambos os grupos ($p > 0,05$). Os resultados da aplicação do teste t e a análise do tamanho do efeito foram reunidos na Tabela 5.


Tabela 5 - Resultados do teste t e o tamanho do efeito para cada parâmetro.

	Teste t (p -valor)	Tamanho do Efeito	
		d Cohen	Interpretação do tamanho do efeito
AuC	2,212 ($p=0,019$)	0,903	Grande
v_{mm}	3,033 ($p=0,003$)	1,238	Grande

Fonte: A autora.


A seguir são mostrados os correlogramas estimados a partir do processamento do sinal obtido do desenho livre da senóide, para os voluntários dos grupos GC e GP, nas Figuras 11 e 12, respectivamente.

Figura 11 - Correlogramas estimados para o grupo GC para o desenho livre. Lag é o atraso de tempo discreto.



Fonte: A autora

Figura 12: Correlogramas estimados para o grupo GP para o desenho livre. Lag é o atraso de tempo discreto.



Fonte: A autora

A Tabela 6 mostra a média e o desvio padrão das características estimadas para cada grupo ao realizarem a tarefa de desenhar a senoide livremente.

Tabela 6 - Média e desvio padrão para v_{mm} e AuC para o desenho livre de cada participante. VC e VP são rótulos que identificam os indivíduos dos grupos GC e GP, respectivamente.

Participante	v_{mm} (média±std)	AuC (média±std)
VC01	0,215 ± 0,141	0,185 ± 0,079
VC02	0,523 ± 0,235	0,260 ± 0,024
VC03	0,296 ± 0,070	0,162 ± 0,029
VC04	0,237 ± 0,161	0,149 ± 0,052
VC05	0,182 ± 0,055	0,206 ± 0,036
VC06	0,276 ± 0,092	0,143 ± 0,050
VC07	0,261 ± 0,118	0,178 ± 0,057
VC08	0,233 ± 0,085	0,190 ± 0,055
VC09	0,243 ± 0,162	0,178 ± 0,085
VC10	0,195 ± 0,094	0,210 ± 0,028
VC11	0,270 ± 0,043	0,169 ± 0,032
VC12	0,201 ± 0,074	0,199 ± 0,031

VP01	0,244 ± 0,071	0,161 ± 0,032
VP02	0,442 ± 0,003	0,065 ± 0,013
VP03	0,354 ± 0,041	0,120 ± 0,013
VP04	0,364 ± 0,068	0,138 ± 0,010
VP05	0,201 ± 0,079	0,198 ± 0,061
VP06	0,388 ± 0,070	0,127 ± 0,027
VP07	0,385 ± 0,073	0,100 ± 0,028
VP08	0,178 ± 0,124	0,205 ± 0,056
VP09	0,385 ± 0,056	0,121 ± 0,022
VP10	0,350 ± 0,033	0,126 ± 0,004
VP11	0,285 ± 0,022	0,168 ± 0,024
VP12	0,416 ± 0,009	0,096 ± 0,026

Fonte: A autora

Após a análise individual, calculou-se a média geral e o desvio padrão das características para cada grupo e o resultado obtido foi um $v_{mm} = 0,261 \pm 0,089$ e $AuC = 0,186 \pm 0,031$ para o CG, e $v_{mm} = 0,332 \pm 0,086$ e $AuC = 0,135 \pm 0,041$ para o grupo GP.

O teste Shapiro-wilk apontou que as amostras do grupo controle não seguiam uma distribuição normal para a variável v_{mm} , desse modo, para a análise dessa característica foi aplicado o teste de Wilcoxon-Mann-Whitney para verificar as diferenças estatísticas; para a variável AuC aplicou-se o t teste. Os resultados da aplicação dos testes t e WMW e a análise do tamanho do efeito pelo δ de Cliff e d de Cohen foram reunidos na Tabela 7.

Tabela 7 - Resultados dos testes de diferença estatística e tamanho de efeito para cada parâmetro

	Teste Estatístico	Tamanho do Efeito	
	Teste t (p-valor)	d Cohen	Interpretação
AuC	3,346 ($p=0,002$)	1,366	Grande
v_{mm}	Teste WMW (w-valor)	δ de Cliff	Interpretação
	107 ($p=0,022$)	0,486	Grande

Fonte: A autora.

5 DISCUSSÃO

O presente trabalho avaliou o desempenho motor de pessoas com a doença de Parkinson através do processamento de sinais inerciais, coletados durante a atividade de desenhar padrões senoidais, e confrontando, estatisticamente, os resultados obtidos com os dados de pessoas

hígidas. Para isso, os sinais de ambos os grupos foram processados, utilizando a linguagem R, onde aplicou-se técnicas de janelamento, suavização, remoção de ruídos, dentre outras, além das análises estatísticas.

Muitos estudos já provaram que os sensores inerciais são eficazes para avaliar o tremor da doença de Parkinson (CAI e colab., 2018; DAI e colab., 2015; JANKOVIC, Joseph e FROST, 1981) mesmo utilizando diferentes métodos de análise. A maioria dos estudos da literatura avalia o desempenho motor da DP através da análise de desenhos em espiral (ALMEIDA e colab., 2012; GUPTA e CHANDA, 2019), porém resultados recentes sugerem a necessidade do uso de padrões senoidais para avaliação do movimento motor fino (FOLADOR e colab., 2020).

O desempenho motor foi avaliado com base em duas características AuC e v_{mm} , estimadas a partir da FAC de sinais do sensor acelerômetro adquiridos enquanto os participantes seguiam um padrão senoidal. Antes da extração das características, os correlogramas dos dois grupos também foram analisados visualmente e percebeu-se que as pessoas do grupo GP apresentaram formas diferentes do correlograma padrão e das pessoas sem a doença. Acredita-se que esse resultado ocorreu devido à influência do tremor parkinsoniano e, no caso da atividade de desenhar a senoide livremente, a dificuldade em realizar a atividade motora sem o contorno da senoide também pode ter contribuído para as diferentes formas dos gráficos.

Além disso, após a análise das características AuC e v_{mm} inferiu-se que as diferenças estatísticas entre os grupos ocorreram devido à influência dos sintomas motores causados pela doença de Parkinson. O resultado da média geral e o desvio padrão das características para cada grupo mostrou que o grupo com a doença de Parkinson foi aquele que apresentou a maior média para a característica v_{mm} , o que indica que os valores dos picos e vales, desse grupo, para ambas as tarefas, se distanciaram mais dos valores dos picos e vales do correlograma de referência. O valor da média geral da área sobre a curva, AuC , foi mais próximo do valor obtido no correlograma de referência para o grupo controle do que para o grupo GP, o que reforça a ideia de que o tremor causado pela doença de Parkinson prejudicou o desempenho motor dos voluntários durante a realização da atividade motora.

No entanto, os correlogramas apresentados nas Figuras 10 e 12 juntamente com os resultados mostrados nas Tabelas 4 e 6 mostram que alguns voluntários com DP tiveram um bom desempenho motor, o que pode ser justificado pela eficácia da terapia medicamentosa (MEMEDI e colab., 2015).

O tamanho do efeito grande para ambas as características sugere que os recursos v_{mm} e AuC são adequados para a avaliação do desempenho motor de pessoas com a doença de

Parkinson. Considerando que o v_{mm} está localizado nos picos e vales, podemos inferir ainda que essa característica contribuiu para a detecção da dificuldade que esses indivíduos tiveram em mudar de direção enquanto seguiam o desenho da senoide ou durante o seu desenho livre. Já a área normalizada sobre a curva nos ajuda a entender a capacidade dos indivíduos em reproduzir as curvas na amplitude e distâncias corretas, e como a média de AuC foi menor para o grupo GP em ambas as atividades, podemos deduzir que o tremor prejudicou a precisão motora desses voluntários.

A principal limitação deste estudo foi não avaliar a relação entre os resultados obtidos e os escores de uma escala clínica como a UPDRS, já que alguns estudos indicaram que os dados do sensor de acelerômetros e giroscópios se correlacionam fortemente com as escalas clínicas (ELBLE, 2006; MOSTILE e colab., 2010; SYNNOTT e colab., 2012). Para esse trabalho essa análise pode ser útil para relacionar a gravidade do distúrbio e seu impacto no desempenho motor fino.

Por fim, foi gerado um pacote contendo todas as funções criadas durante a análise dos sinais que pode ser instalado no RStudio para sua utilização. Os algoritmos utilizados e desenvolvidos nesse projeto encontram-se disponíveis no ANEXO 1.

6 CONCLUSÃO

Conforme apresentado, os recursos abordados nessa pesquisa permitiram a discriminação entre os grupos analisados, GP e GC, mostrando que os voluntários com a doença de Parkinson tiveram um desempenho motor pior quando comparadas as pessoas hígdas. Inferiu-se ainda que esse resultado ocorreu devido a influência do tremor ocasionado pela doença.

Ao final dessa pesquisa foi possível apresentar um método simples e prático para avaliar o desempenho motor com base na análise de características extraídas dos correlogramas gerados pelos sinais inerciais do acelerômetro. Portanto, conclui-se que as características AuC e v_{mm} , estimadas a partir da função autocorrelação, são eficazes para a avaliação do desempenho motor de indivíduos hígdos e com DP.

Além disso, essa técnica poderia ser introduzida na prática clínica para o acompanhamento da doença de Parkinson e como instrumento objetivo para a avaliação da eficácia das terapias medicamentosas e cirúrgicas e para entender a influência do avanço da doença nas habilidades motoras.

7 REFERÊNCIAS

AHMAD, Norhafizan e colab. **Reviews on Various Inertial Measurement Unit (IMU) Sensor Applications**. International Journal of Signal Processing Systems, v. 1, n. 2, p. 256–262, 2013. Disponível em: <<http://www.ijspss.com/index.php?m=content&c=index&a=show&catid=32&id=65>>.

ALMEIDA, M. F. S. e colab. Quantification of physiological kinetic tremor and its correlation with aging. Ago 2012, [S.l.]: IEEE, Ago 2012. p. 2631–2634. Disponível em: <<http://ieeexplore.ieee.org/document/6346504/>>.

ANDRADE, Adriano O e colab. **Sinais e sintomas motores da doença de Parkinson: caracterização, tratamento e quantificação**. Novas tecnologias aplicadas à saúde: integração de áreas transformando a sociedade, p. 282, 2017.

ANTES, Danielle e KATZER, Juliana e CORAZZA, Sara. **Coordenação motora fina e propriocepção de idosas praticantes de hidroginástica**. Revista Brasileira de Ciências do Envelhecimento Humano, v. 5, n. 2 SE-Artigos Originais, 15 Jan 2009. Disponível em: <<http://seer.upf.br/index.php/rbceh/article/view/109>>.

BRAAK, Heiko e colab. **Staging of brain pathology related to sporadic Parkinson's disease**. Neurobiology of Aging, v. 24, n. 2, p. 197–211, Mar 2003. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0197458002000659>>.

BRAGA, Almerinda e colab. **Benefícios do treinamento resistido na reabilitação da marcha e equilíbrio nos portadores da doença de Parkinson**. Rev Dig Vida Saúde, v. 2, p. 9, 2003.

BRYDGES, Christopher R. **Effect Size Guidelines, Sample Size Calculations, and Statistical Power in Gerontology**. Innovation in Aging, v. 3, n. 4, 1 Ago 2019. Disponível em: <<https://doi.org/10.1093/geroni/igz036>>.

CAI, Guoen e colab. **Quantitative assessment of parkinsonian tremor based on a linear acceleration extraction algorithm**. Biomedical Signal Processing and Control, v. 42, p. 53–62, Abr 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809418300089>>.

CALAND, Liana Mayara Queiroz. **Correlação entre a avaliação motora do MDS-UPDRS e o movimento rítmico em indivíduos acometidos pela doença de Parkinson**. 2015. Universidade de Brasília, Brasília, 2015. Disponível em: <<http://repositorio.unb.br/handle/10482/19180>>.

CARVALHO, Liliany Mara Silva e ALVES, Jessica de Castro e LUZ, Tatiana Chama Borges. **Tendência nos gastos com medicamentos neuropsiquiátricos em Minas Gerais, Brasil: há aumento da oferta de antiparkinsonianos?** Ciência & Saúde Coletiva, v. 26, p. 3289–3300, 2021.

CLIFF, Norman. **Answering Ordinal Questions with Ordinal Data Using Ordinal Statistics**. Multivariate Behavioral Research, v. 31, n. 3, p. 331–350, 1 Jul 1996. Disponível

em: <https://doi.org/10.1207/s15327906mbr3103_4>.

CLIFF, Norman. **Dominance statistics: Ordinal analyses to answer ordinal questions.** Psychological Bulletin, v. 114, n. 3, p. 494–509, 1993. Disponível em: <<http://doi.apa.org/getdoi.cfm?doi=10.1037/0033-2909.114.3.494>>.

COHEN, J. **Statistical power for the behavioral sciences.** Hillsdale, NJ: L. . [S.l.]: Erlbaum Associates. , 1988

DAI, Houde e ZHANG, Pengyue e LUETH, Tim. **Quantitative Assessment of Parkinsonian Tremor Based on an Inertial Measurement Unit.** Sensors, v. 15, n. 10, p. 25055–25071, 29 Set 2015. Disponível em: <<http://www.mdpi.com/1424-8220/15/10/25055>>.

DE OLIVEIRA ANDRADE, Adriano. **TREMSSEN-Toolbox.** 2019.

DE SOUZA, DANILO PINTO MOREIRA. **Localização de Faltas em Linha de Transmissão de Energia pela Análise da Função de Autocorrelação.** 2018.

DHALL, Rohit e KREITZMAN, David L. **Advances in levodopa therapy for Parkinson disease.** Neurology, v. 86, n. 14 Supplement 1, p. S13 LP-S24, Abr 2016.

DIAS, Ewerton Naves e PAIS-RIBEIRO, José Luís. **Espiritualidade e qualidade de vida de pessoas idosas: Um estudo relacional.** Psicologia, Saúde & Doenças, v. 19, n. 3, p. 591–604, 2018.

DOS SANTOS, Daliane Cristina e DA SILVA, Emília Pio. **Prevalência da doença de Parkinson relacionada ao auxílio-doença da previdência social.** SAÚDE DINÂMICA, v. 2, n. 2, p. 12–28, 2020.

DOS SANTOS STEIDL, Eduardo Matias e ZIEGLER, Juliana Ramos e FERREIRA, Fernanda Vargas. **Doença de Parkinson: revisão bibliográfica.** Disciplinarum Scientia| Saúde, v. 8, n. 1, p. 115–129, 2007.

ELBLE, Rodger J. **Tremor amplitude is logarithmically related to 4- and 5-point tremor rating scales.** Brain, v. 129, n. 10, p. 2660–2666, 15 Jul 2006. Disponível em: <<https://academic.oup.com/brain/article-lookup/doi/10.1093/brain/aw1190>>.

FAGERLAND, Morten W e SANDVIK, Leiv. **The Wilcoxon-Mann-Whitney test under scrutiny.** Statistics in Medicine, v. 28, n. 10, p. 1487–1497, 10 Maio 2009. Disponível em: <<https://doi.org/10.1002/sim.3561>>.

FERNÁNDEZ PINTO, Janeth. **Magnetometria por efeito Hall.** . [S.l.]: Universidade Federal de Pernambuco. , 2010

FERREIRA, Anderson Henrique Rodrigues. **Análise eletromecânica do giroscópio MEMS.** 2013.

FOLADOR, João Paulo e colab. **Classification of Handwritten Drawings of People with Parkinson's Disease by Using Histograms of Oriented Gradients and the Random Forest**

Classifier. IFMBE Proceedings. [S.l: s.n.], 2020. v. 75. p. 334–343. Disponível em: <http://link.springer.com/10.1007/978-3-030-30648-9_44>.

FRACARO, Nelize. **Estacionariedade das séries temporais do modelo matemático arimax de propulsores eletromecânicos**. 2018. Disponível em: <<http://bibliodigital.unijui.edu.br:8080/xmlui/handle/123456789/5565>>.

FREITAS, Elizabete Viana De e colab. Tratado de geriatria e gerontologia. Tratado de geriatria e gerontologia. [S.l: s.n.], 2006. p. iii–1573.

FULLER, Wayne A. **Introduction to statistical time series**. [S.l.]: John Wiley & Sons, 2009. v. 428.

GUPTA, Jija Das e CHANDA, Bhabatosh. Novel Features for Diagnosis of Parkinson's Disease From off-Line Archimedean Spiral Images. Out 2019, [S.l.]: IEEE, Out 2019. p. 1–6. Disponível em: <<https://ieeexplore.ieee.org/document/8923159/>>.

HELY, M A e colab. **Reliability of the Columbia scale for assessing signs of Parkinson's disease**. Movement disorders : official journal of the Movement Disorder Society, v. 8, n. 4, p. 466–472, Out 1993.

IKE, Daniela. **Análise da incidência de quedas e a influência da fisioterapia no equilíbrio e na instabilidade postural de pacientes com Doença de Parkinson**. Fisioterapia Brasil, v. 9, n. 1, p. 4–8, 30 Dez 2017. Disponível em: <<http://openjournalsolutions.com.br/atlantica/index.php/fisioterapiabrasil/article/view/1597>>.

JABLONSKI, G e colab. AVALIAÇÃO INICIAL DO USO DE UM SENSOR RESISTIVO PARA QUANTIFICAÇÃO DO MOVIMENTO DE PINÇA POLPA-A-POLPA NOS DISTÚRBIOS MOTORES DA DOENÇA DE PARKINSON. 2018, Uberlândia, Minas Gerais: Even3, 2018. Disponível em: <<https://www.even3.com.br/anais/cobecseb/78887>>.

JANKOVIC, J. **Parkinson's disease: clinical features and diagnosis**. Journal of Neurology, Neurosurgery & Psychiatry, v. 79, n. 4, p. 368–376, 1 Abr 2008. Disponível em: <<https://jnnp.bmj.com/lookup/doi/10.1136/jnnp.2007.131045>>.

JANKOVIC, Joseph e FROST, James D. **Quantitative assessment of parkinsonian and essential tremor: Clinical application of triaxial accelerometry**. Neurology, v. 31, n. 10, p. 1235–1235, 1 Out 1981. Disponível em: <<http://n.neurology.org/content/31/10/1235.abstract>>.

KALINKE, Alana Chiapetti. **Associação entre a exposição a agrotóxicos e o desenvolvimento da doença de Parkinson: ênfase na hipótese da vetorização olfatória**. 2017.

KIM, Han Byul e colab. **Wrist sensor-based tremor severity quantification in Parkinson's disease using convolutional neural network**. Computers in Biology and Medicine, v. 95, p. 140–146, Abr 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482518300350>>.

LAKENS, Daniël. **Calculating and reporting effect sizes to facilitate cumulative science:**

a practical primer for t-tests and ANOVAs. *Frontiers in Psychology*, v. 4, p. 863, 2013. Disponível em: <<http://journal.frontiersin.org/article/10.3389/fpsyg.2013.00863/abstract>>.

LEES, Andrew J e HARDY, John e REVESZ, Tamas. **Parkinson's disease.** *The Lancet*, v. 373, n. 9680, p. 2055–2066, 13 Jun 2009. Disponível em: <[https://www.thelancet.com/journals/lancet/article/PIIS0140-6736\(09\)60492-X/fulltext#.Xr_wp5-A5xA.mendeley](https://www.thelancet.com/journals/lancet/article/PIIS0140-6736(09)60492-X/fulltext#.Xr_wp5-A5xA.mendeley)>. Acesso em: 16 maio 2020.

LIMONGI, João Carlos Papaterra. **Conhecendo melhor a Doença de Parkinson.** [S.l.]: Plexus Editora, 2001.

MATTOS, JAMES PITÁGORAS DE. **Diagnóstico diferencial dos tremores.** *Arquivos de Neuro-Psiquiatria*, v. 56, n. 2, p. 320–323, Jun 1998. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0004-282X1998000200027&lng=pt&tlng=pt>. Acesso em: 22 set 2021.

MEINEL, Kurt. **Motricidade I: teoria da motricidade esportiva sob o aspecto pedagógico.** Ao Livro T ed. Rio de Janeiro: [s.n.], 1984.

MELLO, Marcella Patrícia Bezerra De e BOTELHO, Ana Carla Gomes. **Correlação das escalas de avaliação utilizadas na doença de Parkinson com aplicabilidade na fisioterapia.** *Fisioterapia em Movimento*, v. 23, n. 1, p. 121–127, Mar 2010. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-51502010000100012&lng=pt&tlng=pt>.

MEMEDI, Mevludin e colab. **Automatic Spiral Analysis for Objective Assessment of Motor Symptoms in Parkinson's Disease.** *Sensors*, v. 15, n. 9, p. 23727–23744, 17 Set 2015. Disponível em: <<http://www.mdpi.com/1424-8220/15/9/23727>>.

MOREIRA, Camilla Silveira e colab. **Doença de Parkinson: como diagnosticar e tratar.** *Revista Científica da Faculdade de Medicina de Campos*, v. 2, n. 2, p. 19–29, 2007.

MOSTILE, Giovanni e colab. **Correlation between Kinesia system assessments and clinical tremor scores in patients with essential tremor.** *Movement Disorders*, v. 25, n. 12, p. 1938–1943, 15 Set 2010. Disponível em: <<https://doi.org/10.1002/mds.23201>>.

NASIR HUSAIN, Qasim e colab. **Extension of Tukey's Smoothing Techniques.** *Indian Journal of Science and Technology*, v. 9, n. 28, 27 Jul 2016. Disponível em: <<http://www.indjst.org/index.php/indjst/article/view/97354>>.

NUTT, John G e WOOTEN, G Frederick. **Diagnosis and Initial Management of Parkinson's Disease.** *New England Journal of Medicine*, v. 353, n. 10, p. 1021–1027, 8 Set 2005. Disponível em: <<https://doi.org/10.1056/NEJMcp043908>>.

PAIXÃO, A.P.S. e colab. **CARACTERIZAÇÃO DA SEVERIDADE DO TREMOR DE PUNHO EM INDIVÍDUOS COM A DOENÇA DE PARKINSON POR MEIO DE SENSORES INERCIAIS.** 18 Dez 2018, UBERLÂNDIA: Universidade Federal de Uberlândia, 18 Dez 2018. p. 105. Disponível em: <<https://repositorio.ufu.br/handle/123456789/24649>>.

PATEL, S e colab. **Monitoring Motor Fluctuations in Patients With Parkinson's Disease Using Wearable Sensors**. IEEE Transactions on Information Technology in Biomedicine, v. 13, n. 6, p. 864–873, Nov 2009. Disponível em: <<http://ieeexplore.ieee.org/document/5290148/>>.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. . Vienna, Austria: [s.n.], 2020

RAZALI, Nornadiah Mohd e WAH, Yap Bee. **Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests**. Journal of statistical modeling and analytics, v. 2, n. 1, p. 21–33, 2011.

RODRIGUES, Eduardo Sousa Sales. **Desenvolvimento de sistema de captura de movimento humano utilizando IMU**. 2018. Disponível em: <<https://bdm.unb.br/handle/10483/23639>>.

RSTUDIO TEAM. **RStudio: Integrated Development Environment for R**. . Boston, MA: [s.n.], 2019

SAAVEDRA MORENO, Juan Sebastián e MILLÁN, Paula Andrea e BURITICÁ HENAO, Omar Fredy. **Introducción, epidemiología y diagnóstico de la enfermedad de Parkinson**. Acta Neurológica Colombiana, v. 35, n. 3 supl. 1, p. 2–10, 20 Ago 2019. Disponível em: <<https://acnweb.org/es/acta-neurologica-colombiana/1734-introduccion-epidemiologia-y-diagnostico-de-la-enfermedad-de-parkinson.html>>.

SANT, Cíntia e colab. **Abordagem fisioterapêutica na doença de Parkinson**. Revista Brasileira de Ciências do Envelhecimento Humano, v. 5, n. 1 SE-Artigos Originais, 6 Set 2008. Disponível em: <<http://seer.upf.br/index.php/rbceh/article/view/259>>.

SHAEFFER, Derek K. **MEMS inertial sensors: A tutorial overview**. IEEE Communications Magazine, v. 51, n. 4, p. 100–109, Abr 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6495768/>>.

SHAPIRO, S S e FRANCIA, R S. **An Approximate Analysis of Variance Test for Normality**. Journal of the American Statistical Association, v. 67, n. 337, p. 215–216, 1 Mar 1972. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01621459.1972.10481232>>.

SILVA, Ana Paula Sousa Paixão Barroso Da. **O uso de sensores inerciais para caracterização e classificação do tremor de punho em indivíduos com a doença de Parkinson e correlação com a escala de avaliação subjetiva: UPDRS**. 2018. 105 f. Universidade Federal de Uberlândia, UBERLÂNDIA, 2018. Disponível em: <<https://repositorio.ufu.br/handle/123456789/24649>>.

SILVA, Pedro Giovâni Da e BOGONI, Juliano André. **INTRODUÇÃO À ESTATÍSTICA BÁSICA**. Disponível em: <<http://www.liaaq.ccb.ufsc.br/files/2013/10/Aula-4.pdf>>.

SOUSA, Marcos Douglas Rodrigues De. **Principais medidas de magnitude do efeito utilizadas na comparação de dois grupos**. 2018.

SOUSA, Lucas Resende e colab. **O tempo de balanço como variável preditiva da doença de Parkinson.** Fisioterapia e Pesquisa, v. 28, n. 1, p. 95–100, Mar 2021. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1809-29502021000100095&tlng=pt>.

STERN, G. **Did parkinsonism occur before 1817?** Journal of Neurology, Neurosurgery & Psychiatry, v. 52, n. Suppl, p. 11–12, 1 Jun 1989. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/2666573>>.

SYNNOTT, Jonathan e colab. **WiiPD—Objective Home Assessment of Parkinson’s Disease Using the Nintendo Wii Remote.** IEEE Transactions on Information Technology in Biomedicine, v. 16, n. 6, p. 1304–1312, Nov 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6289368/>>.

TAPIA-NÚÑEZ, John e CHANA-CUEVAS, P. **Diagnóstico de la enfermedad de Parkinson.** Rev neurol, v. 38, n. 1, p. 61–67, 2004.

TEIVE, Hélio A. G.; Doença de Parkinson: um guia prático para pacientes e familiares. Doença de Parkinson: conceitos gerais. [S.l.]: São Paulo: Lemos, 2000. p. 31–3.

TEIVE, HÉLIO A.G. **O papel de Charcot na doença de Parkinson.** Arquivos de Neuro-Psiquiatria, v. 56, n. 1, p. 141–145, Mar 1998. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0004-282X1998000100026&lng=pt&tlng=pt>.

WISE, J. **The Autocorrelation Function and the Spectral Density Function.** Biometrika, v. 42, n. 1/2, p. 151, Jun 1955. Disponível em: <<https://www.jstor.org/stable/2333432?origin=crossref>>.

ANEXO 1

O pacote com todas as funções geradas durante o desenvolvimento dessa pesquisa pode ser encontrado no GitHub no link: https://github.com/LimaViviane/NIATS_Pendrawpac.git

```

1 getwd()
2 setwd("C:/Users/VivianeLima/EngBiomedica/TCC/Programas/Dados")
3
4 library("pendrawpac")
5 library("dygraphs")
6
7 ##### SELEÇÃO DO DIRETÓRIO DE ANÁLISE #####
8
9 path_name<-"C:/Users/VivianeLima/EngBiomedica/TCC/Programas/Dados"
10 file_name <- list.dirs(path=path_name, full.names = TRUE,
recursive = TRUE) #Produz um vetor com os nomes dos arquivos do
diretório setado
11
12 filtro <- "^V(.*ESP|.*SEN).txt$" #Expressão contendo a lista de
caracteres dos caminhos que serão retornados pela função list.files
13 direct <- list.files(file_name, pattern= filtro, full.names =
TRUE) #Produz um vetor com os nomes dos caminhos que combinem com os
caracteres de "filtro1"
14
15 file <- direct[1] #0 número indica o arquivo específico a ser
utilizado no processamento
16
17 ##### Carregamento dos dados -----
18
19 dfc <- LoadTREMSenFile(file) #Função pertencente a biblioteca
TREMSen-Toolbox para o carregamento dos dados por meio de um arquivo
.txt
20
21 dygraph(data.frame(time= dfc$X.Time., dfc$X.A1.X.)) #Visualização
dos dados carregados
22
23
24 ##### Separação dos dados do arquivo em dois: tarefa contorno e
desenho livre-----
25
26 dados <- splitData(dfc) #Aplicação da função splitData() que
separa os dados em dois sinais correspondentes a tarefa realizada
27
28 contorno <- dados[["contorno"]] #Seleção do sinal para o
processamento e análise
29
30 dygraph(data.frame(time= contorno$X.Time., contorno$X.A1.X.))
#Visualização dos dados selecionados
31
32 ##### Reamostragem do sinal para 300Hz -----
33
34 dfc1 <- resampleTremsenData(contorno, 300) #Aplicação da função

```

```

resampleTremsenData() que faz a reamostragem do sinal em 300 Hz
35
36 dygraph(data.frame(time= dfc1$X.Time., dfc1$X.A1.X.))
#Visualização dos dados reamostrados
37
38
39 ##### Remoção das tendências lineares e não lineares -----
40
41 dfc2 <- removeTrend(dfc1) #Aplicação da função removeTrend() que
retira as tendências lineares e não-lineares
42
43 dygraph(data.frame(time= dfc2$X.Time., dfc2$X.A1.X.))
#Visualização dos dados sem tendência
44
45
46 ##### Suavização da curva -----
47
48 dfc3 <- smoothing(dfc2) #Aplicação da função smoothing() que faz
a suavização do sinal
49
50 dygraph(data.frame(time= dfc3$X.Time., dfc3$X.A1.X.))
#Visualização dos dados suavizados
51
52
53 ##### Seleção do melhor eixo do acelerômetro -----
54
55 eixo <- selectAxis(dfc1,"S") #Aplicação da função selectAxis()
que seleciona o eixo do acelerômetro que melhor descreve o movimento
realizado
56
57
58 ##### Aplicação da função Autocorrelação -----
59
60 dfacf <- acfApplication(eixo, "S") #Aplicação da função
Autocorrelação e obtenção das características do correlograma (AuC e
v_mm).
61

```

```

1 splitData <- function(df)
2 {
3 dados <- df
4 vectorLabel <- dados$X.PULSE.LABEL
5 vector1 <- as.numeric(levels(vectorLabel)[vectorLabel])
6 timeC <- 0
7 timeCf <- 0
8 timeDL <- 0
9 timeDLf <- 0
10
11 for(i in 1:length(vector1))
12 {
13 if(identical(vector1[i], 1, num.eq = TRUE) && identical(timeC, 0,
num.eq = TRUE)){
14 timeC <- i
15 }

```

```

16 if(identical(vector1[i], 1, num.eq = TRUE) &&
identical(vector1[i+1], 0, num.eq =
TRUE))
17 timeCf <- i
18 }
19
20 for(i in 1:length(vector1))
21 {
22 if(identical(vector1[i], 2, num.eq = TRUE) && identical(timeDL,
0, num.eq = TRUE
)){
23 timeDL <- i
24 }
25 if(identical(vector1[i], 2, num.eq = TRUE) &&
identical(vector1[i+1], 0, num.eq =
TRUE))
26 timeDLf <- i
27 }
28
29
30 contorno <- dados[timeC:timeCf, ]
31 DesLivre <- dados[timeDL:timeDLf, ]
32
33 return(list(contorno = contorno, DesLivre = DesLivre))
34 }
35

```

```

1 removeTrend <- function(df)
2 {
3 dfsinal <- df
4
5 ### Acelerometro 1: X ###
6
7 x1_loessMod75 <- loess(dfsinal$X.A1.X. ~ dfsinal$X.Time.,
data=dfsinal, span=0.75)
# 75% smoothing span
8 x1_smoothed75 <- predict( x1_loessMod75)
9
10 dfsinal$X.A1.X. <- dfsinal$X.A1.X. - x1_smoothed75
11
12
13 ### Acelerometro 1: Y ###
14 y1_loessMod75 <- loess(dfsinal$X.A1.Y. ~ dfsinal$X.Time.,
data=dfsinal, span=0.75)
# 75% smoothing span
15 y1_smoothed75 <- predict(y1_loessMod75)
16
17 dfsinal$X.A1.Y. <- dfsinal$X.A1.Y. - y1_smoothed75
18
19
20 ### Acelerometro 1: Z ###
21 z1_loessMod75 <- loess(dfsinal$X.A1.Z. ~ dfsinal$X.Time.,
data=dfsinal, span=0.75)
# 75% smoothing span
22 z1_smoothed75 <- predict(z1_loessMod75)

```

```

23
24 dfsinal$X.A1.Z. <- dfsinal$X.A1.Z. - z1_smoothed75
25
26 ### Acelerometro 2: X ###
27 x2_loessMod75 <- loess(dfsinal$X.A2.X. ~ dfsinal$X.Time.,
data=dfsinal, span=0.75)
# 75% smoothing span
28 x2_smoothed75 <- predict( x2_loessMod75)
29
30 dfsinal$X.A2.X. <- dfsinal$X.A2.X. - x2_smoothed75
31
32
33 ### Acelerometro 2: Y ###
34 y2_loessMod75 <- loess(dfsinal$X.A2.Y. ~ dfsinal$X.Time.,
data=dfsinal, span=0.75)
# 75% smoothing span
35 y2_smoothed75 <- predict(y2_loessMod75)
36
37 dfsinal$X.A2.Y. <- dfsinal$X.A2.Y. - y2_smoothed75
38
39
40 ### Acelerometro 2: Z ###
41 z2_loessMod75 <- loess(dfsinal$X.A2.Z. ~ dfsinal$X.Time.,
data=dfsinal, span=0.75)
# 75% smoothing span
42 z2_smoothed75 <- predict(z2_loessMod75)
43
44 dfsinal$X.A2.Z. <- dfsinal$X.A2.Z. - z2_smoothed75
45
46
47 return(dfsinal)
48 }

```

```

1 removeSpikes <- function(eixo)
2 {
3
4 k <- boxplot(eixo, plot = FALSE)
5
6 Q3 <- k$stats[4] # Terceiro quartil
7 Q1 <- k$stats[2] # Primeiro quartil
8 IQR <- Q3 - Q1 # distância interquartil
9
10
11 h <- 0.5 * IQR # limiar para detectar os picos indesejados.
12
13 UIF <- as.numeric(Q3 + h)
14
15 LIF <- as.numeric(Q1 - h)
16
17
18 df <- data.frame(time=(1:length(eixo)), signal = eixo)
19 df$UIF <- NA
20 df$LIF <- NA
21
22 indxUIF <- which(eixo > UIF)

```

```

23 indxLIF <-which(eixo < LIF)
24
25 eixo[indxUIF] <- UIF
26 eixo[indxLIF] <- LIF
27
28 return(eixo)
29 }

```

```

1 smoothing <- function(df)
2 {
3   dfsinal <- df
4
5   ### Acelerômetro 1: X ###
6
7   x1_loessMod15 <- loess(dfsinal$X.A1.X. ~ dfsinal$X.Time.,
8     data=dfsinal, span=0.15)
9   # 15% smoothing span
10  x1_smoothed15 <- predict( x1_loessMod15)
11
12  dfsinal$X.A1.X. <- x1_smoothed15
13
14  ### Acelerômetro 1: Y ###
15  y1_loessMod15 <- loess(dfsinal$X.A1.Y. ~ dfsinal$X.Time.,
16    data=dfsinal, span=0.15)
17  # 15% smoothing span
18  y1_smoothed15 <- predict(y1_loessMod15)
19
20  dfsinal$X.A1.Y. <- y1_smoothed15
21
22  ### Acelerômetro 1: Z ###
23  z1_loessMod15 <- loess(dfsinal$X.A1.Z. ~ dfsinal$X.Time.,
24    data=dfsinal, span=0.15)
25  # 15% smoothing span
26  z1_smoothed15 <- predict(z1_loessMod15)
27
28  dfsinal$X.A1.Z. <- z1_smoothed15
29
30  ### Acelerômetro 2: X ###
31  x2_loessMod15 <- loess(dfsinal$X.A2.X. ~ dfsinal$X.Time.,
32    data=dfsinal, span=0.15)
33  # 15% smoothing span
34  x2_smoothed15 <- predict( x2_loessMod15)
35
36  dfsinal$X.A2.X. <- x2_smoothed15
37
38  ### Acelerômetro 2: Y ###
39  y2_loessMod15 <- loess(dfsinal$X.A2.Y. ~ dfsinal$X.Time.,
40    data=dfsinal, span=0.15)
41  # 15% smoothing span
42  y2_smoothed15 <- predict(y2_loessMod15)

```

```

38
39 dfsinal$X.A2.Y. <- y2_smoothed15
40
41
42 ### Acelerômetro 2: Z ###
43 z2_loessMod15 <- loess(dfsinal$X.A2.Z. ~ dfsinal$X.Time.,
data=dfsinal, span=0.15)
# 15% smoothing span
44 z2_smoothed15 <- predict(z2_loessMod15)
45
46 dfsinal$X.A2.Z. <- z2_smoothed15
47
48
49 return(dfsinal)
50 }
51

```

```

1 selectAxis <- function(df, curve) #Utiliza os resultados da função
"Ccf_function"
para selecionar o melhor eixo.
2 {
3 dfsinal <- df
4 tipo <- curve
5 maior <- NA
6
7 X <- NA
8 Y <- NA
9 Z <- NA
10
11 X_comp <- NA
12 Y_comp <- NA
13 Z_comp <- NA
14
15 X <- dfsinal$X.A1.X.
16 Y <- dfsinal$X.A1.Y.
17 Z <- dfsinal$X.A1.Z.
18
19 X_comp <- ccf_function(df = dfsinal, dados = X, curva = tipo)
20 Y_comp <- ccf_function(df = dfsinal, dados = Y, curva = tipo)
21 Z_comp <- ccf_function(df = dfsinal, dados = Z, curva = tipo)
22
23
24 medias <- c(abs(X_comp), abs(Y_comp), abs(Z_comp))
25
26
27 menor_valor <- which(medias %in% min(medias))
28
29 melhor <- as.numeric(menor_valor)
30
31 if(identical(melhor, 1))
32 {
33 print("Melhor eixo: X")
34 return(dfsinal$X.A1.X.)
35 }
36

```

```

37 if (identical(melhor, 2))
38 {
39   print("Melhor eixo: Y")
40   return(dfsinal$X.A1.Y.)
41 }
42
43
44 if (identical(melhor, 3))
45 {
46   print("Melhor eixo: Z")
47   return(dfsinal$X.A1.Z.)
48 }
49
50 }

```

```

1 ccf_function <- function(df, dados, curva)
2 {
3   dfsinal <- df
4   dados <- dados
5   y <- NA
6
7   if(curva == "S")
8   {
9
10    fs <- 300 # frequencia de amostragem (300 Hz)
11    dt <- 1/fs # resolucao temporal
12    tam <- length(dfsinal$X.Time) * dt # tempo maximo em segundos
13    t <- seq(from=0, to=tam,by=dt) # vetor de tempo
14
15    freq <- (length(dfsinal$X.Time)/4) * dt
16    fy <- 1/freq # frequencia de oscilacao do sinal
17
18    senoide <- sin(2*pi*fy*t) # sinal sintetico
19
20    correl <- ccf( dados , senoide, lag.max = length(dfsinal$X.Time),
21      type = c(
22        "correlation"),
23      plot = FALSE)
24
25    y <- correl[["acf"]]
26
27    max_sen <- c(-0.1250000, 0.2499997, -0.3749991, 0.4999978, -
28      0.6249985,
29      0.7499992, -0.8749998, 1.0000000,
30      -0.8749998, 0.7499992, -0.6249985, 0.4999978, -0.3749991,
31      0.2499997, -0.1250000)
32
33    max_sen2 <- abs(max_sen)
34
35    k <- 1
36    j <- 1
37    m <- 1
38
39    maximos <- NA
40    maximos2 <- NA

```

```

36 erro <- NA
37
38 for (l in 2:(length(y)-1)) {
39
40 if((y[l] > y[l-1] & y[l+1] < y[l]) || (y[l-1] > y[l] & y[l+1] >
y[l])) )
41 {
42
43 maximos[k] <- y[l]
44 k <- k+1
45 }
46
47 }
48
49 maximos2 <- abs(maximos)
50
51
52 for (i in 1:15) {
53
54 erro[m] <- max_sen2[i] - maximos2[i]
55 m <- m +1
56 }
57
58 md_erro <- mean(erro)
59
60 return(md_erro)
61
62 }
63
64 if(curva == "E")
65 {
66 dt <- 6*pi/ length(dfsinal$X.Time)
67
68 t <-seq(from=0, to=6*pi, by=dt) #parametro t
69
70 espiral <- data.frame(Eixo.X=1*(t)*cos(t), Eixo.Y=1*(t)*sin(t))
71
72
73 correl <- ccf(dados, espiral$Eixo.Y, lag.max =
length(dfsinal$X.Time), type = c
("correlation"),
74 plot = FALSE)
75
76 y <- correl[["acf"]]
77
78 max_esp <- c(0.00002561342, -0.06631342, 0.1452651, -0.3262855,
0.5156660, -
0.7563879, 1.000000,
79 -0.7563879, 0.5156660, -0.3262855, 0.1452651, -0.06631342,
0.00002561342)
80
81 max_esp2 <- abs(max_esp)
82
83 k <- 1
84 j <- 1
85 m <- 1

```

```

86
87 maximos <- NA
88 maximos2 <- NA
89 erro <- NA
90
91 for (l in 2:(length(y)-1)) {
92
93 if((y[l] > y[l-1] & y[l+1] < y[l]) || (y[l-1] > y[l] & y[l+1] >
y[l])) )
94 {
95
96 maximos[k] <- y[l]
97 k <- k+1
98 }
99
100 }
101
102 maximos2 <- abs(maximos)
103
104
105 for (i in 1:13) {
106
107 erro[m] <- max_esp2[i] - maximos2[i]
108 m <- m +1
109 }
110
111 md_erro <- mean(erro)
112
113 return(md_erro)
114
115
116 }
117
118 }

```

```

1 acfApplication <- function(dt, curve){
2
3 dplotfilt1 <- acf(dt , lag.max = length(dt),
4 type = c("correlation"),
5 plot = TRUE)
6
7 if(curve == "S")
8 {
9 media_vmm <- NA
10 modulo_y1 <- NA
11 AreaTotal1 <- NA
12 pos_vale <- NA
13 pos_pico <- NA
14 x <- NA
15 y <- NA
16
17 x <- dplotfilt1[[4]]
18 y <- dplotfilt1[[1]]
19
20 k <- 1

```

```

21 j <- 1
22
23
24
25 for (l in 2:(length(y)-1)) {
26
27   if((y[l] > y[l-1] & y[l+1] < y[l]) )
28   {
29     pos_pico[k] <- l
30
31     k <- k+1
32   }
33
34   if((y[l-1] > y[l] & y[l+1] > y[l]))
35   {
36     pos_vale[j] <- l
37
38     j <- j+1
39
40   }
41 }
42
43 a <- c(pos_vale, pos_pico)
44
45 pos_vmm <- sort(a)
46
47 max_min <- c(-0.8749997, 0.7499989, -0.6249986, 0.4999996, -
0.3750000,
0.2500000, -0.1249999)
48
49
50 Ep1 <- max_min[2] - y[pos_vmm[2]]
51 Ep2 <- max_min[4] - y[pos_vmm[4]]
52 Ep3 <- max_min[6] - y[pos_vmm[6]]
53
54 Ev1 <- max_min[1] - y[pos_vmm[1]]
55 Ev2 <- max_min[3] - y[pos_vmm[3]]
56 Ev3 <- max_min[5] - y[pos_vmm[5]]
57 Ev4 <- max_min[7] - y[pos_vmm[7]]
58
59 media_vmm <- mean(c(abs(Ep1), abs(Ep2), abs(Ep3), abs(Ev1),
abs(Ev2), abs(Ev3),
abs(Ev4)))
60
61 modulo_y1 <- abs(dplotfilt1[[1]])
62
63 AreaTotal1 <- trapz(dplotfilt1[[4]], modulo_y1)
64
65 return(list(Media_Vmm = media_vmm, Area_total = AreaTotal1))
66 }
67
68
69 if(curve == "E")
70 {
71   media_vmm <- NA
72   modulo_y1 <- NA

```

```

73 AreaTotal1 <- NA
74 pos_vale <- NA
75 pos_pico <- NA
76 x <- NA
77 y <- NA
78
79 x <- dplotfilt1[[4]]
80 y <- dplotfilt1[[1]]
81
82 k <- 1
83 j <- 1
84
85
86 for (l in 2:(length(y)-1)) {
87
88   if((y[l] > y[l-1] & y[l+1] < y[l]) )
89   {
90     pos_pico[k] <- l
91
92     k <- k+1
93   }
94
95   if((y[l-1] > y[l] & y[l+1] > y[l]))
96   {
97     pos_vale[j] <- l
98
99     j <- j+1
100
101   }
102 }
103
104 a <- c(pos_vale, pos_pico)
105
106 pos_vmm <- sort(a)
107
108 max_min <- c(-0.75638792, 0.5156660, -0.3262855, 0.1452651, -
0.06631342)
109
110
111 Ep1 <- max_min[2] - y[pos_vmm[2]]
112 Ep2 <- max_min[4] - y[pos_vmm[4]]
113
114 Ev1 <- max_min[1] - y[pos_vmm[1]]
115 Ev2 <- max_min[3] - y[pos_vmm[3]]
116 Ev3 <- max_min[5] - y[pos_vmm[5]]
117
118 media_vmm <- mean(c(abs(Ep1), abs(Ep2), abs(Ev1), abs(Ev2),
abs(Ev3)))
119
120 modulo_y1 <- abs(dplotfilt1[[1]])
121
122 AreaTotal1 <- trapz(dplotfilt1[[4]], modulo_y1)
123
124 print("Area total:")
125 print(AreaTotal1)
126 print("Media_vmm:")

```

```
127 print(media_vmm)
128
129 return(list(Media_Vmm = media_vmm, Area_total = AreaTotal1))
130 }
131
132 }
```