

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIA ELÉTRICA E BIOMÉDICA

MONIQUE VITÓRIA ARAGÃO DOS SANTOS

ESTIMAÇÃO DO TREMOR PARKINSONIANO UTILIZANDO GIROSCÓPIO PARA EMULAR EM PLATAFORMA EXPERIMENTAL

BELÉM/PA
2026

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIA ELÉTRICA E BIOMÉDICA

MONIQUE VITÓRIA ARAGÃO DOS SANTOS

ESTIMAÇÃO DO TREMOR PARKINSONIANO UTILIZANDO GIROSCÓPIO PARA EMULAR EM PLATAFORMA EXPERIMENTAL

Trabalho de Conclusão de Curso, apresentado à Faculdade de Engenharia Elétrica e Biomédica como requisito parcial para obtenção do Grau de Bacharel em Engenharia Biomédica, pela Universidade Federal do Pará.

Orientador: Prof. Dr. Antonio da Silva Silveira

Coorientador: Prof. Dr. José Augusto Furtado Real

UFPA / ITEC
Campus Universitário do Guamá
Belém-Pará-Brasil
2026

SERVIÇO PÚBLICO FEDERAL
UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIA ELÉTRICA E BIOMÉDICA

ATA DE DEFESA DE TRABALHO DE CURSO (TC)

Ata de defesa de Trabalho de Curso (TC) intitulado: "ESTIMAÇÃO DO TREMOR PARKINSONIANO UTILIZANDO GIROSCÓPIO PARA EMULAR EM PLATAFORMA EXPERIMENTAL", apresentado durante minutos pela discente MONIQUE VITÓRIA ARAGÃO DOS SANTOS, matrícula nº **202106640002**, realizada às **9:30** do dia **19 de junho de 2026**, no **LACOS-UFPA/https://meet.google.com/rya-arax-hym**, sob orientação do Prof. Dr. Antonio da Silva Silveira e coorientação do Prof. Dr. José Augusto Furtado Real. Após a apresentação, a discente foi submetida à arguição oral pelos membros da banca examinadora. Em seguida, a banca se reuniu, em caráter sigiloso, para decidir o resultado do exame, ato que deliberou pela do trabalho com o conceito **EXCELENTE** . Para serem efetuadas as modificações sugeridas pela banca para desenvolver a versão final do Trabalho de Curso, a discente recebeu o prazo máximo de 08 (oito) dias, a contar da data desta defesa. Nada mais havendo a tratar, a sessão foi encerrada, lavrando-se dela a presente Ata que, uma vez aprovada, foi assinada pelos membros da banca examinadora e pela discente.

Documento assinado digitalmente
gov.br ANTONIO DA SILVA SILVEIRA
Data: 23/06/2026 11:55:22-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Antonio da Silva Silveira
(Orientador – UFPA)

Documento assinado digitalmente
gov.br JOSE AUGUSTO FURTADO REAL
Data: 22/06/2026 18:40:52-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. José Augusto Furtado Real
(Coorientador – UFPA)

Documento assinado digitalmente
gov.br WALTER BARRA JUNIOR
Data: 23/06/2026 09:13:14-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Walter Barra Junior
(Membro – UFPA)

Documento assinado digitalmente
gov.br MARIA DA CONCEICAO PEREIRA FONSECA
Data: 22/06/2026 23:26:18-0300
Verifique em https://validar.iti.gov.br

Prof. Dra. Maria da Conceição Pereira Fonseca
(Membro – UFPA)

Documento assinado digitalmente
gov.br MONIQUE VITORIA ARAGAO DOS SANTOS
Data: 22/06/2026 17:53:14-0300
Verifique em https://validar.iti.gov.br

MONIQUE VITÓRIA ARAGÃO DOS SANTOS
(Discente)

Com efeito, grande coisas fez o SENHOR por nós;
por isso, estamos alegres. Sl 126:3

AGRADECIMENTOS

Em primeiro lugar, agradeço ao SENHOR Deus, meu Pai, criador e sustento da minha vida, sem Ele nada seria, a sua Luz é o que me faz viver; sem Ele não estaria onde estou.

Aos meus pais, Mônica Santos e Walter Santos, que sempre me apoiaram, estiveram comigo, lutaram minhas batalhas e abdicaram tanto para que eu tivesse um lar amoroso, acesso à educação e a uma estrutura sólida; sem vocês, eu jamais chegaria onde estou. Ao meu irmão, Walter Neto, pelo apoio e pela amizade. Às minhas tias, Alice Santos e Aline Santos, pelos conselhos, ajuda e amizade. Eu amo vocês.

Aos meus irmãos da igreja Luz Brilhante, pelas orações, palavras de encorajamento e por caminharem ao meu lado ao longo desta trajetória. Aos meus amigos, pelo companheirismo, incentivo e apoio incondicional, tornando essa jornada mais leve e significativa, especialmente diante dos desafios vivenciados na vida acadêmica e pessoal.

Ao professor Antonio Silveira, por acreditar na proposta deste trabalho desde o início e oferecer todo o suporte necessário para sua realização. Ao professor José Augusto Real, pelas valiosas contribuições, sugestões técnicas e apoio ao longo do desenvolvimento do projeto. Ao doutorando Lucas Sodré, pela dedicação, paciência e disponibilidade em compartilhar conhecimentos, contribuindo significativamente para minha formação e para a concretização deste trabalho. Ao Laboratório de Automação e Controle de Sistemas ([1]), grupo ao qual os pesquisadores anteriormente citados estão vinculados, pelo ambiente de excelência acadêmica, incentivo à pesquisa e constante busca por inovação e desenvolvimento científico.

À Siemens Healthineers, empresa da qual faço parte, por me abrir portas para crescer e me desenvolver na profissão que amo. Ao meu gestor, Silas Marinho, pelo incentivo, parceria e amizade. Aos engenheiros de campo que acompanho de perto, Robson Pena e Saullo da Mata, muito obrigada por toda a ajuda, conselhos e por me impulsionarem a melhorar todos os dias.

Meu muito obrigada a todos vocês!

[1] <https://lacos.ufpa.br>

Resumo

A Doença de Parkinson é uma desordem neurodegenerativa cujos sintomas motores, especialmente o tremor, afetam severamente as atividades da vida diária dos pacientes. O desenvolvimento de tecnologias assistivas baseadas em controle ativo surge como uma alternativa promissora para a mitigação dessas oscilações. Nesse contexto, este trabalho tem como objetivo investigar, modelar e reproduzir o tremor Parkinsoniano em uma plataforma experimental física, visando criar um ambiente estruturado e reprodutível para o teste futuro de estratégias de supressão. A metodologia baseou-se no processamento de sinais inerciais advindos de uma Unidade de Medição Inercial (IMU) obtidos de uma base de dados pública. Inicialmente, realizou-se a separação do movimento voluntário do componente patológico, avaliando-se os filtros Criticamente Amortecido (CDF), de Benedict-Bordner e de Kalman. Em seguida, estimou-se o tremor utilizando os algoritmos adaptativos Combinador Linear de Fourier com Frequência Ponderada, Combinador Linear de Fourier Múltiplo com Banda Limitada e o Combinador Linear de Fourier com Frequência Ponderada em cascata com filtro de Kalman. O sinal resultante determinou a referência de deslocamento linear para acionar um mecanismo do tipo biela-manivela-deslizante, comandado por um controlador PID-IMC Internal Model Control), embarcado em um microcontrolador, com realimentação de posição via sensor a laser também filtrado por Kalman. Os resultados indicaram o CDF como o filtro mais eficaz para rastreio do movimento voluntário (KTE de 0,7355), e o WFLC associado ao filtro de Kalman obteve o melhor desempenho na estimação do tremor (FMSEd de 0,2571 rad/s). Na implementação em bancada, a estratégia de controle projetada demonstrou alta robustez, mantendo o erro de rastreamento mecânico em uma faixa restrita de ± 5 mm, superando de forma eficaz as inércias e ruídos inerentes ao sistema físico. Conclui-se que a plataforma validada reproduz o tremor com alta fidelidade, consolidando-se como uma ferramenta viável e essencial para o desenvolvimento e calibração de novos dispositivos assistivos de controle ativo.

Palavras-chave: controle ativo, Parkinson, Sensores Inerciais, Filtro de Kalman, Estimação de tremor.

Abstract

Parkinson's Disease is a neurodegenerative disorder whose motor symptoms, especially tremors, severely affect patients activities of daily living. The development of assistive technologies based on active control emerges as a promising alternative to mitigate these oscillations. In this context, this work aims to investigate, model, and reproduce the Parkinsonian tremor on a physical experimental platform, establishing a structured and reproducible testbench for future suppression strategies. The methodology was based on processing inertial signals (IMU) obtained from a public database. Initially, voluntary movement was separated from the pathological component by evaluating Critically Damped (CDF), Benedict-Bordner, and Kalman filters. Next, the tremor was estimated using the adaptive algorithms *Weighted Frequency Fourier Linear Combiner*, Band-limited Multiple Fourier Linear Combiner , and *Weighted Frequency Fourier Linear Combiner* cascaded with a Kalman Filter. The resulting signal determined the linear displacement reference to drive a slider-crank mechanism, commanded by a PID-IMC controller embedded in an ESP32 microcontroller, with position feedback from a laser sensor also filtered by Kalman. The results indicated the CDF as the most effective filter for voluntary movement tracking (KTE of 0.7355), and the WFLC associated with the Kalman Filter achieved the best performance in tremor estimation (FMSEd of 0.2571 rad/s). In the experimental implementation, the designed control strategy demonstrated high robustness, keeping the mechanical tracking error within a narrow range of ± 5 mm, effectively overcoming the inertia and noise inherent to the physical system. It is concluded that the validated platform reproduces the tremor with high fidelity, consolidating itself as a viable and essential tool for the development and calibration of new active control assistive devices.

Keywords: active control, Parkinson, inertial sensors, Kalman filter, tremor estimation.

Lista de Ilustrações

Figura 1 – Curvas miográficas 21
Figura 2 – Cérebro com e sem a DP. 22
Figura 3 – Comparativo do cerébro 23
Figura 4 – Modelo com dois graus de liberdade de absorção dinâmica. 25
Figura 5 – Dispositivo Vib-bracelet. 26
Figura 6 – Resultados obtidos do Vib-bracelet. 27
Figura 7 – Concepção da LiftWare spoon. 28
Figura 8 – LiftWare spoon. 29
Figura 9 – Tecnologia proposta. 29
Figura 10 – Malha de controle. 30
Figura 11 – Posicionamento dos sensores inerciais. 30
Figura 12 – Plataforma expermiental. 31
Figura 13 – Resultados obtidos. 31
Figura 14 – Unidade de medição inercial 34
Figura 15 – Diagrama de blocos para obtenção das variaveis de um IMU 34
Figura 16 – Acelerômetro MEMS 35
Figura 17 – Modelo com o mecanismo de dois apoios para representação biomecânica. . 50
Figura 18 – Modelo projetado para a representação mecânica do braço. 51
Figura 19 – Sistema que produz o tremor Parkinsoniano 51
Figura 20 – Diagrama de blocos do Controle de Posição. 52
Figura 21 – Sinal bruto adquirido durante o experimento. 62
Figura 22 – Espectro de frequência do sinal bruto (FFT). 63
Figura 23 – Compartivo entre a saída de cada filtro 64
Figura 24 – Comparação espectral entre sinal bruto e sinais filtrados. 64
Figura 25 – Comparação entre sinal bruto e sinal estimado. 65
Figura 26 – Comparação da FFT do sinal bruto e dos sinais filtrados. 66
Figura 27 – Comparação entre sinal bruto e sinal estimado por WFLC. 67
Figura 28 – Comparação entre sinal bruto e sinal estimado por BMFLC. 67
Figura 29 – Comparação entre sinal bruto e sinal estimado por WFLC em cascata com o Filtro de Kalman. 68
Figura 30 – Deslocamento Linear Estimado. 69
Figura 31 – Resposta ao degrau unitário. 70
Figura 32 – Sinal de entrada para excitação visando à identificação. 70
Figura 33 – Toolbox System Identification. 71
Figura 34 – Modelo de 2ª Ordem Aproximado da Planta. 71
Figura 35 – Modelo de 3ª Ordem Aproximado da Planta. 72
Figura 36 – Valores Singulares: Picos das Funções de Sensibilidade T (z) e S(z). 74

Figura 37 – Comparação entre a posição linear estimada, leitura bruta do sensor e a posição filtrada do sistema. 75
Figura 38 – Sinal de controle gerado pelo controlador PID durante o ensaio. 76
Figura 39 – Evolução do erro residual instantâneo confrontado com a dinâmica do sistema. 76

Lista de Tabelas

Tabela 1 – Resultados da métrica KTE para os filtros de movimento voluntário. 65
Tabela 2 – Resultados da métrica FMSEd para os algoritmos de estimação do tremor de Parkinson 68
Tabela 3 – Parâmetros do controlador PID obtidos pelo método IMC 73

LISTA DE ABREVIATURAS E SIGLAS

AVDs	Atividades da Vida Diária
BFLC	*Band-limited Fourier Linear Combiner*
BMFLC	*Band-limited Multiple Fourier Linear Combiner*
CBEB	Congresso Brasileiro de Engenharia Biomédica
CC	Corrente Contínua
CDF	*Critically Damped Filter* (Filtro Criticamente Amortecido)
CGI-S	*Clinical Global Impression - Severity* (Escala de Impressão Clínica Global)
DC	*Direct Current* (Corrente Contínua)
DFT	*Discrete Fourier Transform* (Transformada Discreta de Fourier)
DOF	*Degrees of Freedom* (Graus de Liberdade)
DP	Doença de Parkinson
EM	Eletromagnético
FFT	*Fast Fourier Transform* (Transformada Rápida de Fourier)
FLC	*Fourier Linear Combiner*
FMSEd	*Filtered Mean Square Error with delay correction*
I^2C	*Inter-Integrated Circuit*
IDE	*Integrated Development Environment* (Ambiente de Desenvolvimento Integrado)
IMC	*Internal Model Control* (Controle por Modelo Interno)
IMU	*Inertial Measurement Unit* (Unidade de Medida Inercial)
ITEC	Instituto de Tecnologia
KF	*Kalman Filter* (Filtro de Kalman)
KTE	*Kinetic Tracking Error* (Erro de Rastreamento Cinemático)
LACOS	Laboratório de Sistemas de Controle e Automação

LMS	*Least Mean Squares* (Mínimos Quadrados Médios)
MCP	*Metacarpophalangeal* (Articulação Metacarpofalangeana)
MEMS	*Microelectromechanical Systems* (Sistemas Microeletromecânicos)
MPC	*Model Predictive Control* (Controle Preditivo Baseado em Modelo)
MF	Margem de Fase
MG	Margem de Ganho
MQ	Mínimos Quadrados
PADS	*Parkinson's Disease Smartwatch Dataset*
PID	Proporcional-Integral-Derivativo
PWM	*Pulse Width Modulation* (Modulação por Largura de Pulso)
RMS	*Root Mean Square* (Valor Quadrático Médio)
RMSE	*Root Mean Square Error* (Raiz do Erro Quadrático Médio)
SCL	*Serial Clock Line*
SDA	*Serial Data Line*
SNpc	*Substantia Nigra pars compacta* (Substância Negra pars compacta)
TC	Trabalho de Curso
TMD	*Tuned Mass Damper* (Amortecedor de Massa Sintonizado)
TRS	*Tremor Rating Scale* (Escala de Avaliação do Tremor)
UFPA	Universidade Federal do Pará
VRS	*Visual Rating Scale* (Escala Visual de Avaliação)
WFLC	*Weighted Fourier Linear Combiner*
WTSG	*Wearable Tremor Suppression Glove*

LISTA DE SÍMBOLOS

$\mathbf{A}$	Matriz de transição de estados
$\vec{a}_I, \vec{a}_R$	Vetores aceleração nos referenciais inercial e em rotação
$\mathbf{B}$	Matriz de entrada do sistema
b	Coeficiente de amortecimento viscoso
b^*	Variável auxiliar do erro absoluto
C	Coeficiente de amortecimento da estrutura principal
c	Coeficiente de amortecimento do absorvedor dinâmico
$C(s), C(z)$	Funções de transferência do controlador nos domínios contínuo e discreto
$\hat{d}$	Atraso temporal instantâneo estimado
$e_k, \varepsilon_n, \varepsilon_k$	Erros de estimação ou medição em instantes discretos
$\vec{F}$	Vetor força
f_s	Frequência de amostragem
G	Quantidade de filtros intermediários no banco (BMFLC)
g, h	Ganhos do filtro $g-h$
$\vec{g}$	Vetor aceleração da gravidade
$G(s), G(z)$	Funções de transferência da planta nos domínios contínuo e discreto
GM_{dB}	Margem de ganho estimada
$\mathbf{H}$	Matriz de observação/medição
I, R	Subscritos representando Referencial Inercial e Referencial em Rotação
$\mathbf{I}$	Matriz identidade
J	Momento de inércia equivalente
j	Unidade imaginária
K	Constante de rigidez da estrutura principal

k	Instante discreto de amostragem / Constante de rigidez do absorvedor
$\mathbf{K}$	Matriz de ganho de Kalman
K_d	Ganho derivativo do controlador PID
K_i	Ganho integral do controlador PID
K_p	Ganho proporcional do controlador PID
k_s	Ganho estático da planta
$L(s)$	Função de transferência em malha aberta
M	Massa da estrutura principal / Número de harmônicos
m	Massa inercial do absorvedor / Massa de prova do acelerômetro
M_s, M_t	Picos máximos das funções de sensibilidade $S(s)$ e $T(s)$
N	Comprimento da sequência / Número total de amostras
$\mathbf{P}$	Matriz de covariância do erro de estimação
PM	Margem de fase estimada
$p(k)$	Posição linear estimada
$\mathbf{Q}$	Matriz de covariância do ruído do processo
$\mathbf{R}$	Matriz de covariância do ruído de medição
$\mathbb{R}$	Conjunto dos números reais
$r(k)$	Referência desejada de posição no tempo discreto
$\vec{r}$	Vetor posição da partícula
$S(s), T(s)$	Funções de sensibilidade e sensibilidade complementar
s	Variável complexa de Laplace
T_s	Período de amostragem do sistema
t	Tempo
$u(k)$	Sinal de entrada (aceleração medida)
$\vec{v}$	Vetor velocidade
$v(k)$	Velocidade linear estimada

W_N	Fator de fase discreto (*twiddle factor*)
$\mathbf{w}_k$	Vetor de ruído de processo
$\mathbf{x}$	Vetor de estados do sistema
x	Deslocamento da estrutura principal
x_0	Deslocamento da base
x_1	Deslocamento do absorvedor
$X[k], x[n]$	Sinais no domínio da frequência e do tempo (DFT)
$\mathbf{y}$	Vetor de medições observadas
$\mathbf{z}_k$	Vetor de medição do sensor a laser
α, β	Ganhos do filtro $\alpha - \beta$
Δt	Período de amostragem
ζ	Fator de amortecimento da estrutura principal
ζ_a	Fator de amortecimento do absorvedor dinâmico
θ	Ângulo de deslocamento / Fator de desconto exponencial
μ	Razão de massas / Ganho de adaptação de amplitude
μ_0	Ganho de adaptação de frequência do WFLC
μ_1	Ganho de adaptação de amplitude do WFLC
μ_b	Termo de polarização (*bias*)
σ^2	Variância
τ_c	Torque de controle gerado pelo servomotor
τ_{MF}	Constante de tempo desejada em malha fechada
τ_t	Torque de perturbação associado ao tremor
ϕ	Média do erro absoluto de estimação
ω	Frequência angular instantânea
$\vec{\omega}$	Vetor velocidade angular
ω_0	Frequência fundamental / Limite inferior de banda

ω_a	Frequência natural do absorvedor
ω_f	Limite superior de banda de frequência
Ω_n	Frequência natural da estrutura principal

Sumário

1 INTRODUÇÃO 18
1.1 Objetivo do trabalho 19
1.1.1 Objetivo Geral 19
1.1.2 Objetivos Específicos 19
1.2 Estrutura do Trabalho 19
2 REFERENCIAIS TEÓRICOS 21
2.1 A Doença de Parkinson 21
2.1.1 Aspectos neurológicos da DP 21
2.1.2 Tremor Parkinsoniano 23
2.1.2.1 Tremor em Repouso 24
2.1.2.2 Tremor de Ação 24
2.1.2.2.1 Tremor Postural 24
2.1.2.2.2 Tremor Cinético 24
2.2 Tecnologias Assistivas para Supressão do Tremor 25
2.2.1 Vib-bracelet 25
2.2.2 LiftWare spoon 27
2.2.3 Luva para supressão de ruídos 29
3 METODOLOGIA 32
3.1 Base de Dados e Critérios de Seleção 32
3.2 Unidade de Medição Inercial 33
3.2.1 Acelerômetro 33
3.2.2 Giroscópio 35
3.3 Transformada Rápida de Fourier 37
3.4 Movimento Voluntário e Tremor patológico 38
3.4.1 Estimação do Movimento Voluntário 38
3.4.1.1 Filtros g-h 39
3.4.1.2 Filtro de Benedict-Bordner 40
3.4.1.2.1 Filtro Criticamente Amortecido 41
3.4.1.3 Filtro de Kalman 42
3.4.2 Estimação do Tremor 43
3.4.3 Combinador Linear de Fourier com Frequência Ponderada, Combinador Linear de Fourier Múltiplo com Banda Limitada e Filtro de Kalman 44
3.5 Experimento de Bancada 50
3.5.1 Reprodução do Temor na Estrutura da Manivela Deslizante 50
3.5.2 Controle de Posição para Reprodução do Tremor Estimado 51
4 RESULTADOS E DISCUSSÃO 62
4.1 Caracterização do Sinal 62

4.2 Algoritmos de Estimação do Movimento Voluntário: **63**
4.3 Métrica de desempenho (KTE) dos Algoritmos de estimação do movimento voluntário **65**
4.4 Algoritmos de Estimação do Tremor de Parkinson: **66**
4.5 Métrica de desempenho (FMSEd) dos algoritmos de estimação do tremor Parkinsoniano **68**
4.6 Deslocamento Linear Estimado: **68**
4.7 Resposta da Planta ao Degrau **69**
4.8 Identificação do modelo da planta: **70**
4.9 Sintonia PID-IMC: **72**
4.10 Análise de Estabilidade e Robustez **73**
4.11 Análise dos Resultados Experimentais em Bancada **74**
5 CONCLUSÃO **77**
REFERÊNCIAS **78**

1 INTRODUÇÃO

A Doença de Parkinson (DP), também conhecida como mal de Parkinson, é uma patologia neurológica que afeta a substância negra, uma região do cérebro com função crucial no controle motor. O comprometimento dessa região resulta em alterações motoras significativas nos pacientes acometidos pela doença (HAYES, 2019). A DP é considerada uma doença neurodegenerativa crônica e progressiva, caracterizada principalmente pela diminuição do neurotransmissor dopamina (LATIF et al., 2021).

As manifestações iniciais da Doença de Parkinson incluem o declínio do desempenho motor, afetando diretamente as atividades da vida diária (AVDs) do paciente. Essas limitações podem comprometer não apenas a saúde física, mas também a saúde mental e a participação do indivíduo na vida social (MALAK et al., 2017).

A prevalência da doença de Parkinson vem aumentando de forma contínua nas últimas décadas. Atualmente, estima-se que cerca de 500 mil brasileiros convivam com a comorbidade e que esse número possa chegar a aproximadamente 1,2 milhão em 2060, conFigurando um importante desafio para a saúde pública (SCHLICKMANN et al., 2025).

Nesse contexto, e diante da necessidade de ampliar a autonomia nas AVDs, cresce a demanda por intervenções terapêuticas e soluções tecnológicas capazes de atenuar o tremor Parkinsoniano e melhorar a funcionalidade das pessoas afetadas (SHA et al., 2025).

Neste trabalho, técnicas de estimação do tremor Parkinsoniano são investigadas a partir de um banco de dados de sinais inerciais com o uso de uma Unidade de Medição Inercial (IMU), permitindo a decomposição entre o movimento voluntário e a componente patológica do sinal. Posteriormente, por meio de fusão sensorial, estima-se a posição linear do tremor em um eixo específico, utilizada como referência para o acionamento de uma estrutura biela-manivela-deslizante responsável por reproduzir mecanicamente a oscilação característica do tremor. A validação do sistema é realizada com auxílio de um sensor óptico a laser, por meio da comparação entre a posição estimada e a posição real do mecanismo. Para o rastreamento da posição desejada, utiliza-se um controlador PID-IM (Internal Model Control) associado ao filtro de Kalman, visando melhorar a suavização do sinal e a robustez da resposta dinâmica. Além disso, foi realizada a modelagem matemática da planta e a análise da sintonia do controlador PID-IMC, avaliando critérios de estabilidade, desempenho e robustez do sistema em malha fechada. Como contribuição principal, o trabalho propõe o desenvolvimento de uma plataforma experimental capaz de simular o tremor Parkinsoniano de forma controlada e reprodutível, fornecendo um ambiente de testes para futuras pesquisas e para a avaliação de tecnologias assistivas voltadas à redução dos impactos motores da doença, visando ampliar a autonomia e a qualidade de vida das pessoas acometidas pela patologia.

1.1 Objetivo do trabalho

1.1.1 Objetivo Geral

Compreender e caracterizar o tremor da DP, reproduzindo-o em uma plataforma experimental utilizando um mecanismo biela-manivela-deslizante.

1.1.2 Objetivos Específicos

Para alcançar o objetivo geral deste trabalho, são estabelecidas etapas que envolvem a análise de dados dos tremores, a modelagem do ruído e a reprodução em uma estrutura física. Com base nessas etapas, definem-se, a seguir, os objetivos específicos:

1. Analisar o banco de dados de sinais inerciais contendo registros de tremores associados a DP.
2. Caracterizar o sinal no domínio do tempo e da frequência, identificando padrões relevantes para modelagem.
3. Modelar o comportamento dos tremores a partir dos dados analisados, utilizando o Matlab para simulação.
4. Modelar e construir uma plataforma física de emulação do tipo biela-manivela-deslizante, acionada por motor CC (Corrente Contínua) e controlada por microcontrolador.
5. Projetar e analisar a sintonia de um controlador PID-IMC para o rastreamento da trajetória do tremor reproduzido pela plataforma.
6. Validar a plataforma experimental comparando o deslocamento mecânico real com a posição estimada na simulação.

1.2 Estrutura do Trabalho

Este documento organiza-se em cinco capítulos:

- **Capítulo 1**: Apresenta o contexto geral da pesquisa, o objetivo geral e os específicos.
- **Capítulo 2**: Fundamentação teórica sobre a Doença de Parkinson, abordando seus aspectos com ênfase nas características dos tremores Parkinsonianos. Além disso, apresenta uma revisão das tecnologias assistivas existentes para a mitigação dos tremores.

- **Capítulo 3**: Metodologia adotada na pesquisa, incluindo a descrição do banco de dados de sensores inerciais utilizado, as etapas de pré-processamento e análise dos sinais, a modelagem do tremor Parkinsoniano e a concepção da estrutura física experimental. Este capítulo detalha a construção de plataformas para simulação do tremor, assim como a integração de um sensor óptico para avaliação dos resultados.
- **Capítulo 4**: Apresentação e análise dos resultados obtidos, tanto da modelagem do tremor quanto do desempenho do protótipos desenvolvido.
- **Capítulo 5**: Conclusões e trabalhos futuros.
- **Referências**: Bibliografia consultada e fundamentação científica.

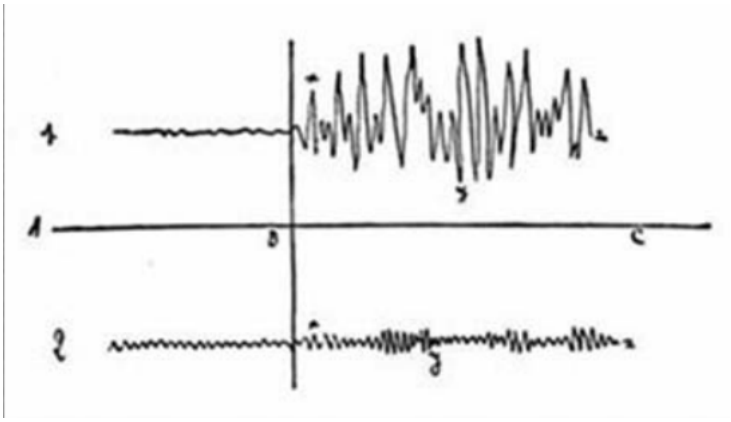
2 REFERENCIAIS TEÓRICOS

2.1 A Doença de Parkinson

2.1.1 Aspectos neurológicos da DP

A Doença de Parkinson foi descrita de maneira sistemática e em termos médicos em 1817 por James Parkinson. Ao longo do século XIX, Jean-Martin Charcot desempenhou um papel fundamental no refinamento da caracterização clínica da doença, contribuindo significativamente para a consolidação do conceito moderno da DP. Charcot desenvolveu um protocolo clínico detalhado a partir da observação sistemática de pacientes atendidos no Hospital da Salpêtrière, em Paris. Em suas análises, o autor avaliava o comportamento do tremor em repouso e durante a execução de movimentos voluntários. Charcot observou que pacientes com Doença de Parkinson apresentavam tremor tanto em repouso quanto durante atividades motoras, diferentemente dos pacientes com esclerose múltipla, nos quais a intensidade do tremor aumentava significativamente com o esforço. Essas observações foram registradas por meio das chamadas “curvas miográficas”. Conforme ilustrado na Figura 1, o traçado superior representa o tremor de intenção típico da esclerose múltipla, no qual o segmento AB corresponde ao repouso e o segmento BC demonstra o aumento das oscilações durante o movimento voluntário. Em contraste, o traçado inferior representa o tremor Parkinsoniano, caracterizado pela presença de tremor em repouso (segmento AB), que persiste durante a realização de movimentos voluntários (segmento BC). A partir dessa análise, Charcot concluiu que, na Doença de Parkinson, não há uma relação significativa entre o esforço motor e a intensidade do tremor, diferentemente do que ocorre em outras patologias neurológicas (GOETZ, 2011).

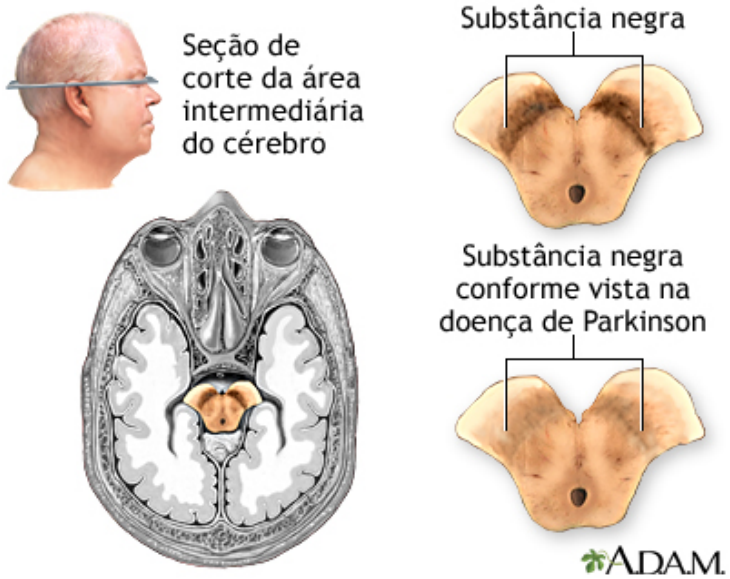
Figura 1 Curvas miográficas



Fonte: Adaptado de Goetz (2011), com base em Charcot (1887).

A DP conFigura-se como a segunda enfermidade neurodegenerativa de caráter progressivo mais frequente em escala mundial, sendo superada apenas pela doença de Alzheimer (SU et al., 2025). Essa condição é marcada, sobretudo, pela degeneração da via dopaminérgica nigroestriatal, no entanto, o processo neurodegenerativo não se limita exclusivamente aos neurônios dopaminérgicos localizados na substância negra, envolvendo também outras estruturas e sistemas do sistema nervoso (LONG; REUTHER, 2025). A Figura 2 representa a diferença observada entre um cérebro com DP e um sem a patologia.

Figura 2 Cérebro com e sem a DP.



Fonte: ADAM Health Solutions Editorial Team (2021).

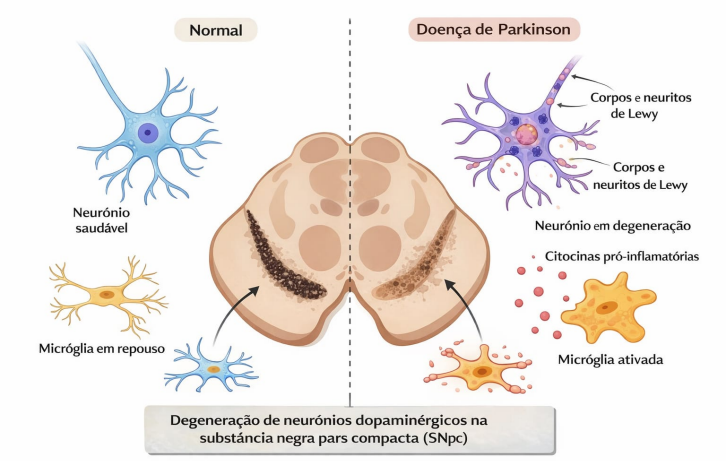
A morte neuronal progressiva acarreta uma redução expressiva dos níveis de dopamina nos gânglios da base, culminando em um distúrbio do movimento caracterizado pelos principais sintomas motores da Doença de Parkinson, como tremor em repouso, rigidez muscular, bradicinesia e instabilidade postural (KALIA; LANG, 2015). Contudo, evidências clínicas atuais indicam que a doença apresenta um espectro sintomatológico mais amplo, não se restringindo às manifestações motoras, mas incluindo também sintomas não motores frequentes, tais como distúrbios do sono, alterações autonômicas, comprometimento cognitivo, sintomas depressivos e disfunções sensoriais, os quais podem preceder ou acompanhar a evolução dos sintomas motores (PENA-ZELAYETA et al., 2025)

O tratamento principal da DP baseia-se na administração de medicamentos que repõem a dopamina ou atuam na estimulação de seus receptores, com o objetivo de atenuar os déficits funcionais decorrentes da perda dopaminérgica. Apesar dos avanços na terapêutica, ainda não existem métodos diagnósticos que possibilitem a confirmação definitiva da doença em seus estágios iniciais (MUNHOZ et al., 2024).

Atualmente, o diagnóstico definitivo da Doença de Parkinson é estabelecido por meio da análise neuropatológica post-mortem, na qual se observa a degeneração da substância negra pars

compacta (SNpc) associada à presença da patologia de Lewy, como ilustrado na Figura 3. Esta é caracterizada pela formação de inclusões intracelulares anormais compostas pela proteína α-sinucleína, proteína fundamental para a função motora. Em condições patológicas, a α-sinucleína sofre agregação anormal, dando origem aos corpos de Lewy e neuritos de Lewy.Embora esses achados sejam considerados marcadores patológicos da doença, os mecanismos que explicam sua relação direta com a patogênese da Doença de Parkinson ainda não estão totalmente elucidados (CASTONGUAY; GRAVEL; LEVESQUE, 2021).

Figura 3 Comparativo do cerébro .



Fonte: Adaptado de Castonguay; Gravel; Levesque (2021) .

Até o presente momento, não foram estabelecidas terapias modificadoras da doença capazes de retardar a neurodegeneração ou interromper a progressão da Doença de Parkinson. Assim, o desenvolvimento de intervenções que atuem diretamente nos mecanismos patológicos subjacentes à doença permanece como uma das principais demandas ainda não atendidas no contexto da Doença de Parkinson (VIJIARATNAM et al., 2021).

2.1.2 Tremor Parkinsoniano

O tremor Parkinsoniano constitui um dos sintomas motores de maior prevalência da doença, estando presente em uma parcela significativa dos indivíduos acometidos (ABUSRAIR; ELSEKAILY; BOHLEGA, 2022). O tremor é definido como um movimento oscilatório involuntário que pode acometer uma ou mais partes do corpo. Na Doença de Parkinson, esse movimento adquire características patológicas específicas, estando associado à perda da função motora resultante da degeneração dopaminérgica. Do ponto de vista clínico, os tremores podem ser classificados principalmente em tremor de repouso e tremor de ação (LENKA; JANKOVIC, 2021).

2.1.2.1 Tremor em Repouso

O tremor em repouso é caracterizado por movimentos rítmicos e oscilatórios quando o membro está relaxado. Esse tipo de tremor apresenta frequência geralmente na faixa de 4 a 6 Hz, possui variação de amplitude e é vulnerável a estressores ambientais. Apesar de estar associado à doença, não ocorre em todos os pacientes e apresenta grande variabilidade clínica. Embora a perda dopaminérgica seja necessária para a ocorrência do tremor em repouso, muitos pacientes não obtêm melhora com a reposição dopaminérgica e, em alguns casos, podem até apresentar piora, sugerindo que esse tipo de tremor pode possuir outras causas. Além disso, o tremor em repouso tende a ser suprimido ou significativamente reduzido quando o paciente inicia uma ação voluntária, o que o distingue de outros tipos de tremor, como o tremor de ação (MENDONCA et al., 2024).

2.1.2.2 Tremor de Ação

O tremor de ação consiste em movimentos oscilatórios involuntários que ocorrem durante a execução de movimentos voluntários, como segurar um objeto ou manter a postura em pé. Esse tipo de tremor apresenta tipicamente frequências entre 6 e 15 Hz (LAINE; VALERO-CUEVAS, 2020). O tremor de ação pode ser subdividido em dois tipos principais:

2.1.2.2.1 Tremor Postural

O tremor postural está associado à dificuldade de manter a estabilidade muscular ao sustentar uma posição contra a gravidade, como ao estender os braços à frente ou segurar um objeto por um determinado período de tempo (BUTLER et al., 2025).

2.1.2.2.2 Tremor Cinético

O tremor cinético ocorre durante movimentos voluntários dinâmicos e compromete principalmente a execução de tarefas motoras finas, como escrever ou desenhar. Para avaliar sua gravidade, é frequentemente utilizada uma escala visual (Visual Rating Scale, VRS), que atribui uma pontuação de 0 a 9 com base na análise do desenho espiral, permitindo quantificar a intensidade do tremor (LIN et al., 2018).

A análise objetiva do tremor de ação, incluindo seus subtipos postural e cinético, é relevante tanto para monitorar a progressão da doença quanto para avaliar a eficácia de intervenções terapêuticas, contribuindo para estratégias clínicas que visam melhorar a função motora e a qualidade de vida dos pacientes (LAINE; VALERO-CUEVAS, 2020).

2.2 Tecnologias Assistivas para Supressão do Tremor

Existem diversas tecnologias assistivas aplicadas à Doença de Parkinson (DP), que abrangem tanto abordagens invasivas quanto não invasivas (SÁNCHEZ-FERRO et al., 2016) . Entre as tecnologias invasivas, destacam-se terapias como a infusão contínua de levodopa por meio de bomba (MARSILI et al., 2021), enquanto as abordagens não invasivas se baseiam, principalmente, na supressão ou atenuação do tremor por meios mecânicos ou eletrônicos, incluindo dispositivos com sistemas embarcados. Essas tecnologias têm como objetivo promover o bem-estar do paciente, melhorar sua qualidade de vida e ampliar sua autonomia funcional nas atividades de vida diária (MIRA et al., 2022).. De modo geral, as tecnologias assistivas voltadas à DP variam desde soluções de alta complexidade tecnológica até dispositivos desenvolvidos em contextos experimentais ou acadêmicos, algumas das quais são apresentadas a seguir.

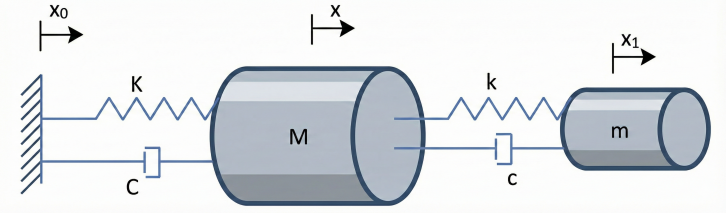
2.2.1 Vib-bracelet

O Vib-bracelet é uma solução passiva desenvolvida com o objetivo de atenuar os movimentos de pronação e supinação do antebraço. Seu funcionamento fundamenta-se no princípio da absorção dinâmica de vibrações lineares, que consiste na adição de um absorvedor acoplado ao sistema vibratório principal. Nesse contexto, o antebraço humano constitui o sistema vibratório principal, enquanto o bracelete acoplado ao punho atua como absorvedor dinâmico. Para a análise do tremor, a grandeza inercial relevante é o momento de inércia do antebraço em torno de seu eixo longitudinal (BUKI et al., 2018).

De acordo com a arquitetura proposta pelos autores, o absorvedor dinâmico é composto por três elementos fundamentais: massa (M), mola (K) e amortecimento (C). Esse conjunto é projetado de forma que sua frequência natural coincida com a frequência da vibração que se deseja atenuar, maximizando a eficiência do processo de absorção.

Nesse sentido, o sistema ilustrado na Figura 4 apresenta um modelo com dois graus de liberdade, no qual a supressão da vibração é obtida por meio do acoplamento de um absorvedor caracterizado por uma massa inercial (m), uma mola (k) e um amortecedor (c). Com a sintonização adequada desses parâmetros, é possível reduzir significativamente a resposta vibratória da estrutura principal quando submetida a uma excitação externa.

Figura 4 Modelo com dois graus de liberdade de absorção dinâmica.



Fonte: Adaptado de BUKI et al. (2018).

Considerando x_0 como a posição da base, x como o deslocamento da estrutura principal e x_1 como o deslocamento do absorvedor, o comportamento dinâmico do sistema pode ser descrito pelo seguinte conjunto de equações diferenciais:

$$\begin{cases} M\ddot{x} = K(x_0 - x) + C(\dot{x}_0 - \dot{x}) + k(x_1 - x) + c(\dot{x}_1 - \dot{x}) \\ m\ddot{x}_1 = c(\dot{x} - \dot{x}_1) + k(x - x_1) \end{cases} \tag{2.1}$$

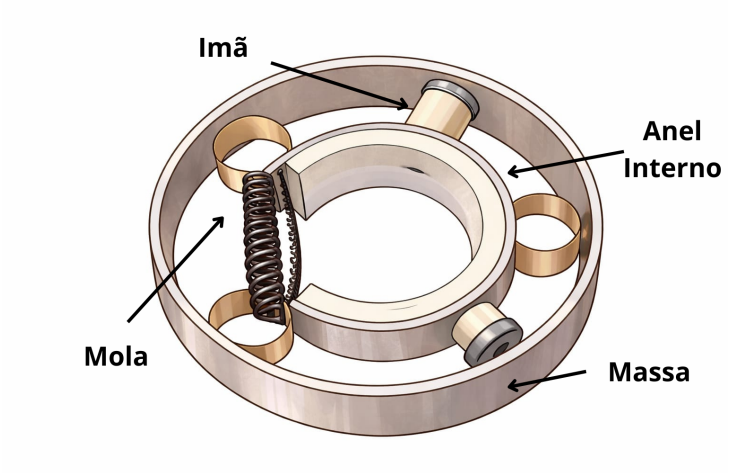
A partir dessas equações, a função de transferência do sistema é dada por:

$$\frac{X}{X_0} = \frac{(2\zeta\Omega_n s + \Omega_n^2)(s^2 + 2\zeta_a\omega_a s + \omega_a^2)}{(s^2 + 2\zeta\Omega_n s + \Omega_n^2)(s^2 + 2\zeta_a\omega_a s + \omega_a^2) + \mu s^2(2\zeta_a\omega_a s + \omega_a^2)} \tag{2.2}$$

A análise desse modelo revela que o comportamento dinâmico desse conjunto é definido por parâmetros fundamentais. As frequências naturais da estrutura principal ($\Omega_n\sqrt{K/M}$) e do absorvedor ($\omega_a = \sqrt{k/m}$) dependem diretamente da relação entre a massa e a constante elástica de cada componente. Os coeficientes de amortecimento ($\zeta = \frac{C}{2\sqrt{KM}}$ e $\zeta_a = \frac{c}{2\sqrt{km}}$) determinam a taxa de dissipação de energia vibratória, enquanto a razão de massa ($\mu = m/M$) estabelece a proporção entre a massa do absorvedor e a da estrutura principal. Quando o absorvedor encontra-se sub-sintonizado, isto é, quando $\omega_a < \Omega_n$, observa-se uma redução do ganho máximo do sistema, cenário considerado ideal para a absorção das frequências associadas ao tremor Parkinsoniano.

Ainda conforme o estudo citado, ao ser sintonizado na faixa típica de frequência do tremor patológico, aproximadamente entre 4 e 6 Hz, o dispositivo promove a atenuação da resposta vibratória do membro superior. O amortecimento é realizado por meio de um mecanismo passivo de amortecimento magnético, baseado no efeito de correntes parasitas (eddy currents). Nesse processo, ímãs induzem correntes elétricas no anel externo durante o movimento relativo entre os anéis, permitindo a dissipação de energia sem contato mecânico direto e sem a necessidade de uma fonte externa de energia. O dispositivo está ilustrado na Figura 5.

Figura 5 Dispositivo Vib-bracelet.

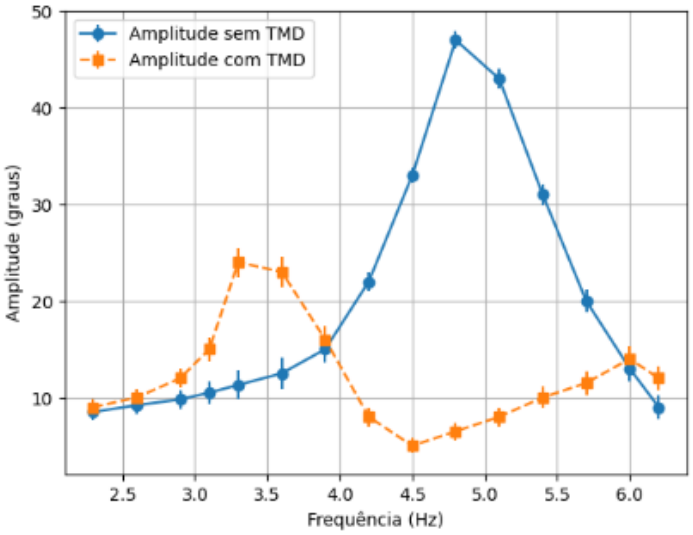


Fonte: Adaptado de BUKI et al. (2018).

Quanto aos dados experimentais reportados, os resultados experimentais indicam que o dispositivo apresenta eficácia na faixa de 4 a 5,75 Hz, alcançando uma atenuação máxima de 86%. Em contrapartida, nas frequências de 2,25 Hz e 3,25 Hz, observou-se uma amplificação da amplitude do movimento. No entanto, há indícios de que esse comportamento não comprometa significativamente as Atividades de Vida Diária, o que reforça o potencial do Vib-bracelet como uma alternativa viável para pessoas acometidas pela Doença de Parkinson.

Na Figura 6, esses resultados podem ser visualizados, evidenciando um comportamento típico de um Tuned Mass Damper (TMD), ou amortecedor de massa sintonizado, princípio de funcionamento do próprio Vib-bracelet. Observa-se a atenuação da amplitude de vibração do sistema principal na faixa de frequência para a qual o dispositivo foi sintonizado. A curva em azul representa a resposta do sistema sem o uso do dispositivo, enquanto a curva amarela evidencia a redução significativa da amplitude quando o Vib-bracelet é utilizado. Contudo, o dispositivo ainda necessita de estudos adicionais para aumentar sua confiabilidade e viabilizar a sintonização em frequências específicas para cada indivíduo com Doença de Parkinson.

Figura 6 Resultados obtidos do Vib-bracelet.

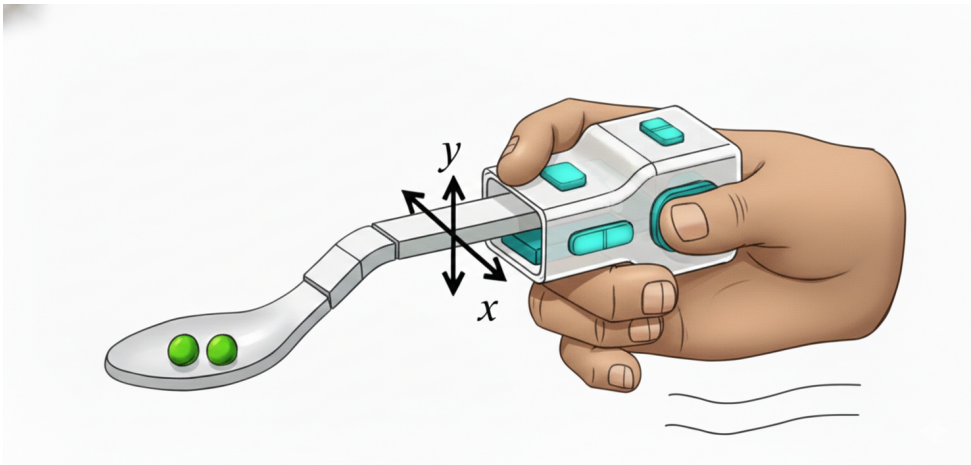


Fonte: Adaptado de BUKI et al. (2018).

2.2.2 LiftWare spoon

Um estudo piloto conduzido por Pathak et al. (2014) demonstrou que o LiftWare foi capaz de reduzir a amplitude do tremor entre 71% e 76% durante tarefas funcionais relacionadas à alimentação, indicando benefícios para indivíduos com tremor leve a moderado. Contudo, o dispositivo não é indicado para casos de tremor severo, e os resultados devem ser interpretados com cautela, em virtude do tamanho reduzido da amostra e do envolvimento dos próprios desenvolvedores no estudo, o que reforça a necessidade de investigações clínicas adicionais e independentes.

Figura 7 Concepção da LiftWare spoon.



Fonte: Adaptado de Pathak et al. (2014).

Segundo detalhado pelos autores, a tecnologia empregada no LiftWare baseia-se em um sistema ativo de estabilização estruturado em quatro subsistemas fundamentais: a colher, uma plataforma geradora de movimento, um conjunto de controlador/sensor e a unidade de alimentação. O funcionamento ocorre através de um acelerômetro triaxial embutido na base da colher, que detecta, em tempo real, os movimentos involuntários nos eixos horizontal (x) e vertical (y). Esses sinais são processados pelo controlador, que aciona dois motores CC internos conectados a juntas mecânicas. Estes motores geram movimentos compensatórios em fase oposta ao tremor, promovendo a estabilização imediata do utensílio, enquanto a energia é fornecida por uma bateria recarregável situada no cabo.Para validar essa tecnologia, foram realizados ensaios clínicos que avaliaram a gravidade do tremor dos participantes através da escala TRS.

O estudo consistiu na execução de três tarefas funcionais com o dispositivo ligado e desligado, em um protocolo duplo-cego: segurar a colher entre a mesa e a boca, realizar o movimento de comer levando blocos de espuma aos lábios e transferir esses blocos para um copo a 75 cm de distância. Além da avaliação clínica, os participantes registraram sua percepção de melhora por meio da Escala de Impressão Clínica Global (CGI-S), quantificando o impacto do dispositivo na facilidade de execução das tarefas.O desempenho técnico foi analisado via processamento de dados de aceleração, coletados a uma taxa de 100 Hz.

O sinal foi tratado com um filtro passa-banda de 2 a 25 Hz para remover ruídos e isolar o tremor dos movimentos voluntários e dos efeitos gravitacionais. Utilizando a Transformada Rápida de Fourier (FFT), o estudo identificou a frequência dominante e a magnitude da aceleração, permitindo calcular a amplitude real do tremor através da dupla integração dos dados e da norma euclidiana das direções de movimento. Essa metodologia de extração de sinal, validada por câmeras de alta velocidade e processamento de imagem em MATLAB, permitiu registrar a redução efetiva do deslocamento da colher, comprovando que o sistema compensa eficazmente as oscilações, que geralmente apresentam picos de amplitude em frequências próximas a 5 Hz.

A ilustração do princípio de funcionamento e o dispositivo comercializado estão apresentados nas Figuras 7 e 8, respectivamente.

Figura 8 LiftWare spoon.

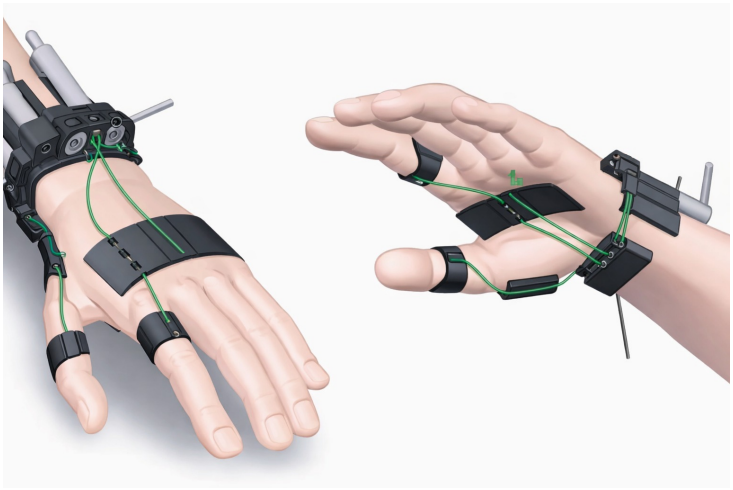


Fonte: Adaptado de CADTH (2016).

2.2.3 Luva para supressão de ruídos

A luva proposta, ilustrada na Figura 8, é um dispositivo projetado para a supressão do tremor Parkinsoniano. Ela consiste em uma estrutura leve que envolve os dedos e o punho, equipada com cabos que transmitem forças controladas por motores localizados no punho, permitindo atuar nas articulações do dedo indicador, polegar e punho sem comprometer os movimentos voluntários do usuário (ZHOU et al., 2018).

Figura 9 Tecnologia proposta.

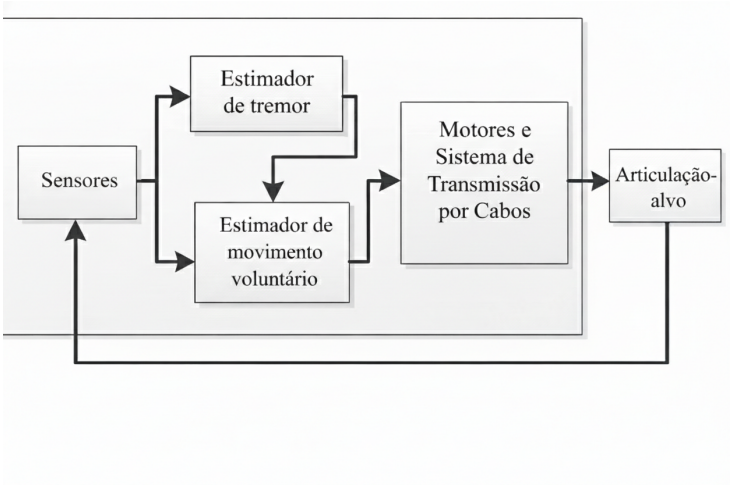


Fonte: Adaptado de Zhou et. al (2018).

O sistema opera por meio de uma malha de controle que se inicia com os dados obtidos pelos sensores inerciais e termina com a atuação dos motores nas articulações, como ilustrado na Figura 10. Na prática, os ângulos das articulações são derivados da velocidade angular medida por Unidades de Medida Inercial (IMUs) distribuídas estrategicamente pela mão. Como a velocidade angular não reflete o ângulo articular de forma direta, o sistema executa um algoritmo

de integração no início de cada ciclo de controle para calcular o deslocamento angular preciso. A disposição dos sensores está disposta na Figura 11.

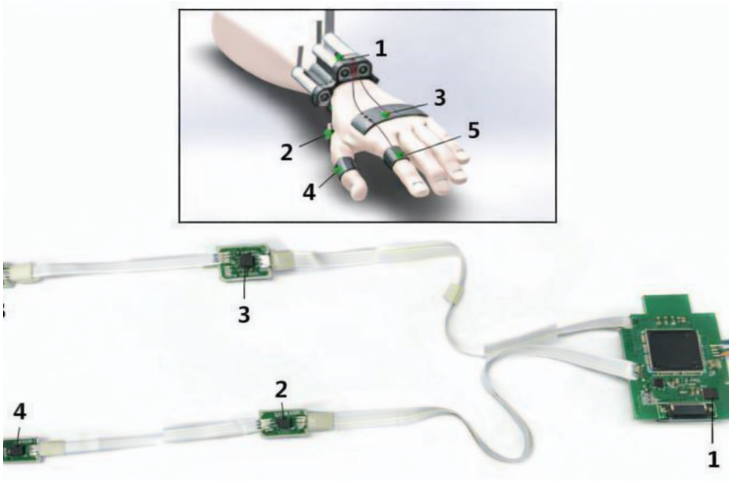
Figura 10 Malha de controle.



Fonte: Adaptado de Zhou et. al (2018).

Este conjunto de sensores captura o movimento total da mão, que compreende tanto a componente do movimento voluntário quanto a do tremor involuntário. Para processar esses sinais, o sistema emprega algoritmos avançados de estimação, destacando-se o Combinador Linear de Fourier de Frequência Ponderada (WFLC) e os filtros de Kalman. Essas ferramentas são responsáveis por isolar a componente do tremor, identificando suas frequências características e eliminando ruídos de sinal. Uma vez que o movimento voluntário é estimado, ele serve como o sinal de referência para o controle dos motores. Estes motores atuam ajustando a tensão em cabos não elásticos para suprimir as oscilações indesejadas, garantindo que ocorra a mínima interferência no movimento intencional do usuário.

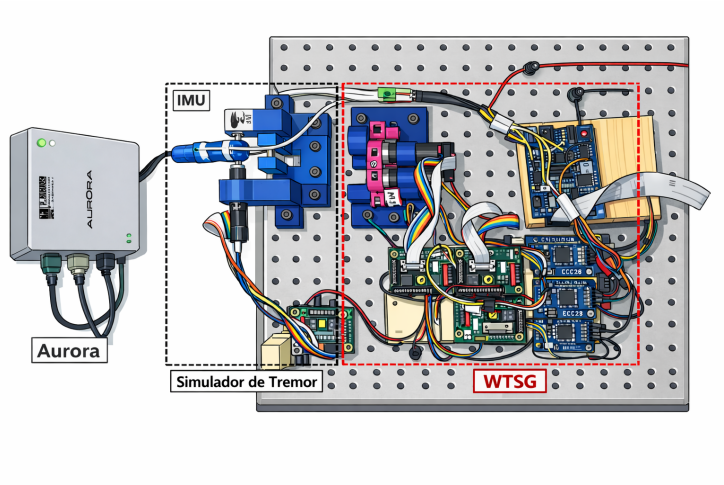
Figura 11 Posicionamento dos sensores inerciais.



Fonte: Adaptado de Zhou et. al (2018).

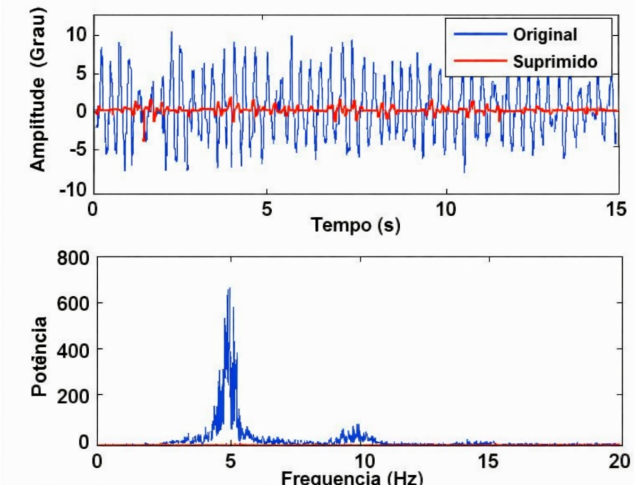
A validação desse sistema, denominado WTSG (Wearable Tremor Suppression Glove), em português, luva vestível para supressão de tremor, foi realizada em uma plataforma experimental que utiliza um simulador de tremor para replicar torques reais. Com base em dados clínicos, o torque de tremor na articulação MCP do dedo indicador foi quantificado com um valor RMS de $0,02 \pm 0,02$ Nm e amplitude máxima de $0,06 \pm 0,05$ Nm. O simulador reproduz dois cenários distintos extraídos de pacientes reais: o tremor em repouso e o movimento voluntário sob efeito de tremor (movimento oscilatório). Durante os testes, um dedo impresso em 3D é utilizado como suporte, e a precisão do sistema é verificada através de um sistema de rastreamento eletromagnético (EM) de 5 graus de liberdade (Aurora, NDI), operando em conjunto com os IMUs a uma frequência de amostragem de 40 Hz via software LabVIEW; A ilustração da plataforma experimental encontra-se na Figura 12. O protótipo da luva demonstrou uma redução média de 85,0% ± 8,1% na amplitude do tremor, evidenciando a eficácia do dispositivo em condições simuladas. O resultado apresentado pelos autores está ilustrado na Figura 13.

Figura 12 Plataforma expermiental.



Fonte: Adaptado de Zhou et. al (2018).

Figura 13 Resultados obtidos.



Fonte: Adaptado de Zhou et. al (2018).

3 METODOLOGIA

Com a finalidade de avaliar o uso de um protótipo para reprodução de tremores Parkinsonianos, este trabalho propõe uma abordagem estruturada que integra análise de dados, modelagem matemática e validação experimental. Inicialmente, busca-se compreender as características do tremor, permitindo uma análise detalhada do comportamento dinâmico do sinal.

A partir desses dados, realiza-se a decomposição entre os componentes de movimento voluntário e involuntário (tremor), etapa crucial para a precisão das fases subsequentes. O tremor é então estimado para obter uma representação fiel do fenômeno. Utilizando fusão sensorial, determina-se o deslocamento linear em um eixo, que serve de entrada para uma bancada de excitação mecânica. Esta estrutura reproduz o sinal estimado por meio de técnicas de controle de posição, enquanto um sensor óptico valida os resultados, medindo o deslocamento real.

3.1 Base de Dados e Critérios de Seleção

Os dados utilizados neste trabalho foram obtidos a partir do banco de dados público PADS (Parkinson's Disease Smartwatch Dataset), disponibilizado na plataforma PhysioNet (VARGHESE et al., 2024). Esse conjunto de dados foi desenvolvido com o objetivo de investigar biomarcadores digitais associados a distúrbios do movimento, como a Doença de Parkinson e o Tremor Essencial, por meio de sensores inerciais embarcados em dispositivos vestíveis.

O repositório contempla registros de 469 indivíduos, incluindo pacientes com diferentes condições neurológicas e indivíduos saudáveis (grupo de controle). Para este estudo, foi selecionado o registro de um paciente idoso com diagnóstico de Parkinson idiopático, termo que indica o desenvolvimento espontâneo da condição sem uma causa secundária identificável, durante a execução do teste dedo-nariz. Esse teste consiste em um movimento voluntário direcionado, no qual o indivíduo estende o braço e toca a ponta do próprio nariz com o dedo, sendo amplamente utilizado na avaliação clínica da coordenação motora e na identificação de tremores cinéticos (CAMPBELL, 2005; BRAZIS; MASDEU; BILLER, 2016).

A escolha de um indivíduo em idade avançada fundamenta-se no fato de que o envelhecimento está associado à redução da velocidade e da largura de banda dos movimentos voluntários. Dessa forma, torna-se improvável que tais movimentos ocorram em frequências superiores a 2 Hz, o que favorece a separação entre o componente voluntário e o tremor patológico (GALLEGO et al., 2010).

Sob o ponto de vista espectral, a análise cinemática de membros superiores em tarefas de precisão, como o teste dedo-nariz, evidencia uma distinção clara entre os componentes do

movimento. Os movimentos voluntários concentram-se predominantemente em baixas frequências, raramente excedendo o patamar de 2,5 Hz, situando-se tipicamente no intervalo de 0,48 Hz a 2,47 Hz. Essa separação em frequência constitui a base para a modelagem e filtragem dos sinais, permitindo o isolamento do tremor como um componente de maior frequência (RIVIERE; THAKOR, 1996).

3.2 Unidade de Medição Inercial

As Unidades de Medição Inercial (IMUs) constituem uma tecnologia consolidada, originalmente desenvolvida para aplicações de navegação em foguetes e naves espaciais. Sua adoção em larga escala teve início durante a Segunda Guerra Mundial, com o desenvolvimento de mísseis guiados, sendo posteriormente expandida para a aviação comercial (TAZARTES, 2014). Nas últimas décadas, entretanto, a aplicação desses sensores diversificou-se significativamente, abrangendo áreas que vão desde a engenharia aeroespacial até a engenharia biomédica. Destaca-se, nesse contexto, sua integração em dispositivos vestíveis, voltados à estimação de posição e orientação corporal (KOZLOVSZKY et al., 2018). Um componente genérico desse tipo é ilustrado na Figura 14.

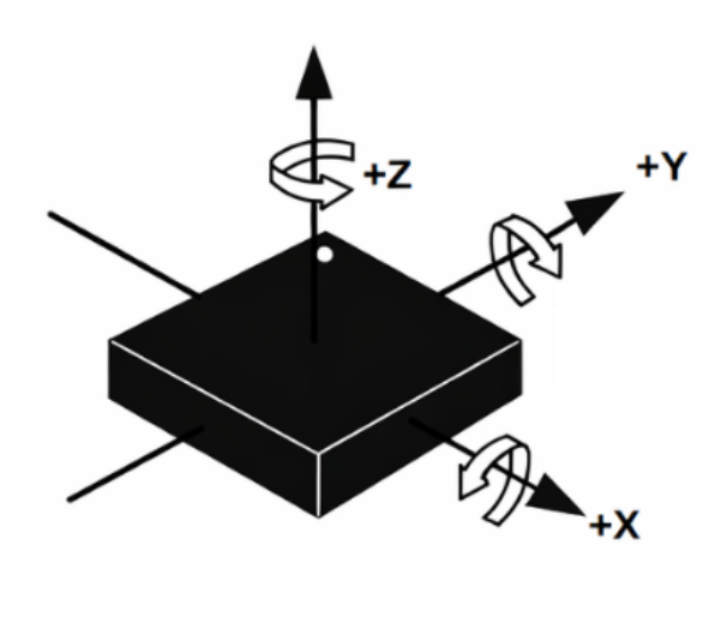
O banco de dados escolhido utiliza uma Unidade de Medição Inercial (IMU) baseada em tecnologia de Sistemas Microeletromecânicos (MEMS) para a análise das oscilações dos membros superiores. O sistema opera com seis graus de liberdade (6-DOF) a partir do processamento conjunto de acelerômetros e girômetros. Conforme ilustrado no diagrama de blocos da Figura 15, o fluxo de dados inicia-se com a integração da velocidade angular obtida pelo giroscópio para a determinação da orientação do sensor. Essa informação é essencial para o bloco de rotação, que alinha a aceleração linear medida pelo acelerômetro antes que esta seja submetida a uma dupla integração numérica: a primeira integral converte a aceleração em velocidade linear, enquanto a segunda resulta na estimação da posição espacial do dispositivo, mapeando assim o deslocamento linear do membro analisado (WOODMAN, 2007).

3.2.1 Acelerômetro

Os acelerômetros apresentam ampla aplicação em diversas áreas da engenharia. Entretanto, possuem limitações relevantes, principalmente pelo fato de medirem a aceleração total, que inclui tanto componentes dinâmicos quanto a aceleração gravitacional. Do ponto de vista físico, um acelerômetro pode ser modelado como um sistema massa–mola–amortecedor de segunda ordem, como ilustrado na Figura 16. Nesse sistema, uma massa de prova suspensa por molas sofre deslocamento quando submetida à aceleração, sendo esse deslocamento proporcional ao sinal elétrico de saída. Em dispositivos MEMS, esse princípio é implementado por meio de uma

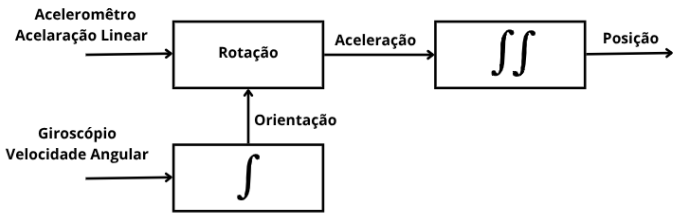
estrutura microscópica de silício, na qual a aceleração provoca o deslocamento da massa e a variação da capacitância entre eletrodos fixos e móveis (DELATORRE, 2020).

Figura 14 Unidade de medição inercial



Fonte: Autoria própria

Figura 15 Diagrama de blocos para obtenção das variaveis de um IMU

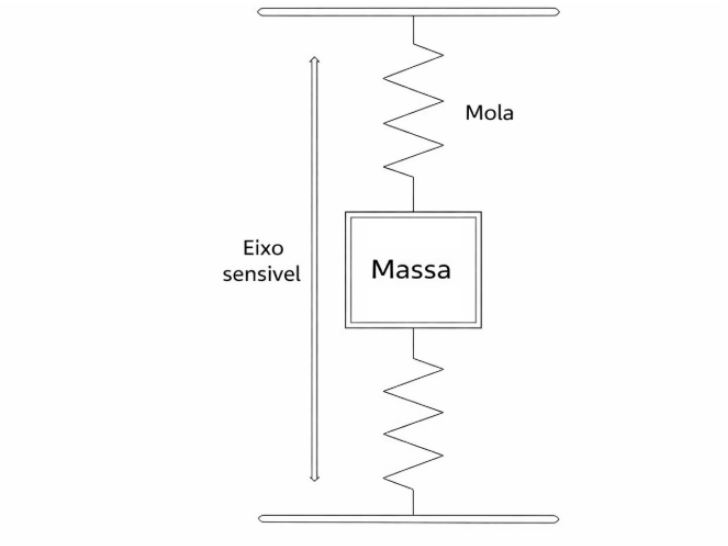


Fonte: Autoria própria

A medição da aceleração em sensores inerciais fundamenta-se na distinção entre dois componentes: a aceleração estática, ligada ao vetor gravidade $\vec{g}$ e usada para estimar a inclinação do dispositivo, e a aceleração dinâmica, que registra o movimento real do corpo. O grande desafio técnico surge porque a gravidade está sempre presente no sinal, mesmo em repouso. Como qualquer mudança na orientação do sensor altera a forma como a gravidade é projetada em seus eixos, e considerando que a magnitude de $\vec{g}$ varia ligeiramente dependendo da localização geográfica, essa oscilação se mistura aos movimentos voluntários e aos tremores patológicos. Essa indissociabilidade é uma limitação crítica, pois variações de inclinação ou de gravidade local podem mimetizar ou esconder componentes dinâmicos, dificultando a separação precisa entre o que é movimento intencional e o que é sintoma clínico no sinal coletado (WOODMAN, 2007; TITTERTON; WESTON, 2004).

Ademais, a inferência de estados cinemáticos, como a velocidade e o deslocamento rotacional, a partir de dados brutos de aceleração requer sucessivas etapas de integração numérica e filtragem. Este processo é severamente comprometido pela presença do bias (polarização) do sensor. O bias define-se como um erro sistemático que se manifesta como um offset (deslocamento) constante na saída do transdutor, mesmo na ausência de movimento externo. Devido à natureza da integração matemática, este erro residual é propagado e acumulado, resultando em uma deriva (drift) que cresce linearmente na velocidade e quadraticamente no deslocamento ao longo do tempo. Outro fator determinante para a robustez do sistema é a sensibilidade do acelerômetro à sua orientação relativa ao campo gravitacional terrestre. Variações na estabilidade do bias e erros de cross-eixo (sensibilidade cruzada decorrente do desalinhamento mecânico entre os eixos de medição) exigem procedimentos de calibração rigorosos e algoritmos de compensação dinâmica (EGER; PORATH; DONATELLI, 2025).

Figura 16 Acelerômetro MEMS



Fonte: Autoria própria

3.2.2 Giroscópio

O giroscópio mede a velocidade angular nos três eixos espaciais, permitindo que a orientação do sistema seja estimada por meio da integração dessa velocidade ao longo do tempo. O princípio operacional do dispositivo baseia-se no efeito de Coriolis: quando o sensor é submetido a uma rotação, surge uma força inercial perpendicular à direção do movimento de uma massa vibrante interna. Nos dispositivos MEMS, essa força de Coriolis provoca uma alteração na vibração de elementos micromecânicos, como sensores piezoelétricos ou capacitivos, resultando em uma deformação detectável. Essa deformação gera um sinal elétrico proporcional à taxa de rotação, de forma que a medição da velocidade angular está diretamente relacionada à intensidade da força de Coriolis atuante sobre a massa vibrante (WOODMAN, 2007).

Historicamente, o nome desse fenômeno deriva de Gaspard-Gustave de Coriolis, que o descreveu em 1835 durante seus estudos sobre o movimento relativo em sistemas rotacionais. A força de Coriolis é classificada como uma força inercial, uma vez que se manifesta apenas quando o movimento é analisado a partir de um referencial não inercial em rotação. Fisicamente, ela atua de forma perpendicular tanto à velocidade linear da massa vibrante quanto ao eixo de rotação do sistema, sendo essa característica vetorial o que permite ao sensor distinguir e quantificar o movimento em diferentes direções (DELATORRE, 2020).

O efeito de Coriolis pode ser compreendido ao considerar dois sistemas de referência distintos: um inercial e outro em rotação com velocidade angular constante $\vec{\omega}$. Denota-se o referencial inercial por I e o referencial em rotação por R, enquanto t representa o tempo, $\times$ indica o produto vetorial, e v_{arb} corresponde a um vetor arbitrário em $\mathbb{R}^3$ (GOLDSTEIN; POOLE; SAFKO, 2014). Então:

$$\left(\frac{d}{dt}\right)_I = \left(\frac{d}{dt}\right)_R + \vec{\omega} \times v_{arb} \tag{3.1}$$

Se $\vec{r}$ é a posição de uma partícula com massa m no referencial inercial, sua derivada temporal nos dois referenciais relaciona-se por:

$$\left(\frac{d\vec{r}}{dt}\right)_I = \left(\frac{d\vec{r}}{dt}\right)_R + \vec{\omega} \times \vec{r} \tag{3.2}$$

Ao definir $\left(\frac{d\vec{r}}{dt}\right)_I$ como a velocidade da partícula no referencial inercial, $\vec{v}_I$, e $\left(\frac{d\vec{r}}{dt}\right)_R$ como a velocidade no referencial em rotação, $\vec{v}_R$, a equação (3.2) pode ser reformulada da seguinte forma:

$$\vec{v}_I = \vec{v}_R + \vec{\omega} \times \vec{r} \tag{3.3}$$

A partir da eq. (3.3) pode ser obtida a aceleração da partícula nos dois referenciais:

$$\begin{aligned}
\vec{a}_I = \left(\frac{d\vec{v}_I}{dt}\right)_I &= \left(\frac{d\vec{v}_I}{dt}\right)_R + \vec{\omega} \times \vec{v}_I \\
&= \left[\frac{d}{dt}(\vec{v}_R + \vec{\omega} \times \vec{r})\right]_R + \vec{\omega} \times (\vec{v}_R + \vec{\omega} \times \vec{r}) \\
&= \left(\frac{d\vec{v}_R}{dt}\right)_R + \left(\frac{d\vec{\omega}}{dt}\right)_R \times \vec{r} + \vec{\omega} \times \left(\frac{d\vec{r}}{dt}\right)_R + \vec{\omega} \times \vec{v}_R + \vec{\omega} \times (\vec{\omega} \times \vec{r}) \\
&= \vec{a}_R + \dot{\vec{\omega}} \times \vec{r} + 2\vec{\omega} \times \vec{v}_R + \vec{\omega} \times (\vec{\omega} \times \vec{r}).
\end{aligned} \tag{3.4}$$

Multiplicando os dois lados da equação pela massa da partícula m:

$$m\vec{a}_I = m\vec{a}_R + m\dot{\vec{\omega}} \times \vec{r} + 2m\vec{\omega} \times \vec{v}_R + m\vec{\omega} \times (\vec{\omega} \times \vec{r}). \tag{3.5}$$

Definindo $\vec{F}_I \equiv m\vec{a}_I$ e $\vec{F}_R \equiv m\vec{a}_R$ como as forças que atuam sobre a partícula nos referenciais inercial e rotativo, respectivamente, um observador no referencial em rotação percebe que a partícula está sujeita à seguinte força:

$$\vec{F}_R = \vec{F}_I - m\dot{\vec{\omega}} \times \vec{r} - m\vec{\omega} \times (\vec{\omega} \times \vec{r}) - 2m\vec{\omega} \times \vec{v}_R \tag{3.6}$$

Dessa forma, além da força que atua sobre a partícula no referencial inercial ($\vec{F}_I$), existem outras três forças que dependem da rotação do referencial. A primeira é a força de Euler, expressa como $-m\dot{\vec{\omega}} \times \vec{r}$, que surge devido à variação da velocidade angular do referencial no tempo. A segunda é a força centrífuga, expressa como $-m\vec{\omega} \times (\vec{\omega} \times \vec{r})$, presente permanentemente no referencial rotativo. A terceira, $-2m\vec{\omega} \times \vec{v}_R$, aparece apenas quando a partícula se movimenta em qualquer direção que não coincida com $\vec{\omega}$; esta é conhecida como a força de Coriolis. A partir dessas medições, é possível determinar a aceleração e a velocidade angular do dispositivo e identificar a rotação completa de todo o sistema (GOLDSTEIN; POOLE; SAFKO, 2014).

Nesse contexto, o uso de giroscópios possibilita uma representação mais precisa da dinâmica do movimento articular, uma vez que fornece diretamente a velocidade angular, reduzindo erros de integração e estimações indiretas. Isso proporciona maior fidelidade tanto na modelagem do movimento quanto no desenvolvimento de estratégias de controle (GALLEGO et al., 2010).

Para este estudo, optou-se por utilizar os dados de um dos eixos fornecidos pelo giroscópio, pois esse sensor mede diretamente a velocidade angular dos segmentos corporais, sendo particularmente adequado para a análise de movimentos articulares predominantemente rotacionais.

3.3 Transformada Rápida de Fourier

A Transformada Discreta de Fourier (DFT, do inglês *Discrete Fourier Transform*) é a ferramenta fundamental para a análise espectral de sinais amostrados. Ela permite a decomposição de uma sequência finita de amostras no domínio do tempo em seus componentes de frequência constituintes. A DFT de uma sequência discreta $x[n]$ de comprimento N é definida matematicamente pela Equação 3.7 (OPPENHEIM; SCHAFER, 2010):

$$X[k] = \sum_{n=0}^{N-1} x[n] W_N^{kn}, \quad k = 0, 1, \ldots, N-1 \tag{3.7}$$

Onde W_N representa o fator de fase, ou fator de *twiddle*, dado por:

$$W_N = e^{-j\left(\frac{2\pi}{N}\right)} \tag{3.8}$$

Visto que $x[n]$ pode assumir valores complexos, o cálculo direto da Equação 3.7 exige aproximadamente N^2 multiplicações e adições complexas. Essa complexidade computacional, de ordem $O(N^2)$, torna-se proibitiva para sistemas de processamento em tempo real ou para grandes volumes de dados (OPPENHEIM; SCHAFER, 2010).

Para contornar essa limitação, utiliza-se a Transformada Rápida de Fourier (FFT, do inglês *Fast Fourier Transform*). A FFT não é uma nova transformação, mas sim um algoritmo eficiente que explora propriedades de simetria e periodicidade do fator de fase para reduzir a complexidade computacional para $O(N \log_2 N)$ (OPPENHEIM; SCHAFER, 2010). Neste estudo, essa técnica será utilizada para análise e comparação entre a faixa de frequência do movimento voluntário e Parkinsoniano.

3.4 Movimento Voluntário e Tremor patológico

Como as faixas de frequência associadas ao movimento voluntário e ao tremor patológico são distintas, o sinal medido $x(t)$ pode ser modelado como a superposição de duas componentes:

$$x(t) = x_{vol}(t) + x_{tremor}(t) \tag{3.9}$$

em que $x_{vol}(t)$ representa o movimento voluntário e $x_{tremor}(t)$ corresponde ao tremor patológico.

A partir dessa modelagem, o algoritmo proposto para estimação do tremor é estruturado em duas etapas. A primeira consiste na separação da componente de movimento voluntário, para a qual serão avaliadas duas classes de filtros preditivos: os filtros *g-h* (também conhecidos como filtros α-β) e o filtro de Kalman. Em seguida, a componente de tremor será estimada por meio de técnicas específicas, como o Weighted Fourier Linear Combiner (WFLC), o Band-limited Fourier Linear Combiner (BFLC) e também o filtro de Kalman.

A escolha de filtros preditivos, em detrimento de abordagens clássicas como filtros passa-baixa ou médias móveis, deve-se ao fato de que estes últimos introduzem atraso de fase no sinal filtrado. Do ponto de vista de sistemas lineares, esse atraso está associado à resposta em fase do filtro, que provoca um deslocamento temporal entre o sinal de entrada e o sinal de saída, esse deslocamento é prejudicial em sistemas que atuam em tempo real pois o sistema pode reagir para algo que já ocorreu há algum tempo (OPPENHEIM; SCHAFER, 2010).

3.4.1 Estimação do Movimento Voluntário

O movimento voluntário pode ser descrito como ocorrendo na faixa de 0 a 2 Hz; portanto, todas as componentes de frequência acima desse intervalo devem ser desconsideradas. Esse movimento também pode ser representado por meio de uma expansão em série de Taylor, con-

forme indicado na eq. (3.10). Sob a hipótese de que o período de amostragem é suficientemente pequeno e/ou que a aceleração é baixa, o termo de segunda ordem pode ser negligenciado. Dessa forma, o movimento pode ser adequadamente modelado como um processo de primeira ordem (GALLEGO et al., 2010).

$$x(t+T_s) \approx x(t) + \dot{x}(t)T_s \tag{3.10}$$

3.4.1.1 Filtros g-h

Os filtros g-h, também conhecidos como filtros α-β (alpha-beta), constituem uma classe de filtros recursivos amplamente utilizados para estimação de estados em sistemas dinâmicos, especialmente em problemas de rastreamento, sendo muito utilizados na aeronáutica e no rastreamento por radar. Esses filtros são fundamentados em um modelo simplificado da dinâmica do sistema, geralmente descrito por uma equação de primeira ordem, assumindo movimento com velocidade aproximadamente constante ao longo de pequenos intervalos de tempo (BROOKNER, 1998).

A ideia central do filtro g-h é combinar duas etapas principais: predição e correção. Na etapa de predição, o estado futuro da variável de interesse (tipicamente posição) é estimado com base no estado atual e na velocidade estimada, utilizando um modelo matemático simples do processo. Em seguida, na etapa de correção, essa estimação é ajustada a partir de novas medições, levando em consideração o erro entre o valor previsto e o valor medido (GALLEGO et al., 2010).

O funcionamento do filtro $g-h$ pode ser compreendido como um processo iterativo composto por duas etapas principais: predição e correção. Esse mecanismo baseia-se na projeção do estado atual para um instante futuro a partir de um modelo cinemático simples e na posterior correção dessa estimativa com base em medições experimentais (BROOKNER, 1998).

A cada instante discreto k, o filtro recebe uma medição y_k, que representa o valor observado do sistema. A partir de uma estimativa prévia da posição $p_{k|k-1}$, realiza-se a etapa de correção com base no erro entre a medição e a predição, definido como:

$$e_k = y_k - p_{k|k-1} \tag{3.11}$$

A correção da posição é realizada por meio de um ganho g, que atua como fator de ponderação entre a predição e a medição. Valores elevados de g indicam maior confiança nos dados medidos, enquanto valores reduzidos resultam em uma estimação mais suave, menos sensível a ruídos.

De forma complementar, o parâmetro h ajusta a estimação da velocidade com base no erro observado na posição. As equações da etapa de correção são dadas por:

$$p_{k|k} = p_{k|k-1} + g_k(y_k - p_{k|k-1}) \tag{3.12}$$

$$v_{k|k} = v_{k|k-1} + \frac{h}{T_s}(y_k - p_{k|k-1}) \tag{3.13}$$

Após a correção, o filtro realiza a etapa de predição, projetando o estado para o próximo instante de tempo $k+1$, assumindo um modelo de velocidade constante. As equações de predição são descritas por:

$$p_{k+1|k} = p_{k|k} + T_s\, v_{k|k} \tag{3.14}$$

$$v_{k+1|k} = v_{k|k} \tag{3.15}$$

3.4.1.2 Filtro de Benedict-Bordner

O filtro de Benedict-Bordner representa uma evolução teórica na aplicação dos filtros α-β, ao transformar a seleção dos ganhos em um problema de otimização matemática. Originalmente proposto por Benedict e Bordner em 1962, o objetivo central era encontrar uma relação ótima entre os parâmetros α-β ou *g*-*h* que minimizasse o erro de rastreamento sob condições conflitantes de ruído de medição e manobras do alvo (BENEDICT; BORDNER, 1962).

A fundamentação deste filtro baseia-se na minimização de um funcional de custo que pondera dois domínios de erro:

1. Variância do Erro em Regime Permanente (σ_e^2): Representa o erro causado pelo ruído branco de medição do sensor. Um filtro focado exclusivamente neste parâmetro seria excessivamente lento para responder a mudanças bruscas de estado.
2. Erro Transiente Total (E_t): Representa a soma acumulada dos desvios entre a posição real e a estimada quando o sistema sofre uma variação súbita.

Benedict e Bordner demonstraram que o erro transiente total é inversamente proporcional à capacidade de suavização de ruído. Através do cálculo de variações, os autores provaram que, para que um filtro apresente o menor erro transiente possível para um dado nível de redução de ruído, os ganhos devem satisfazer a seguinte relação:

$$h = \frac{g^2}{2-g} \tag{3.16}$$

Esta expressão, conhecida como a *Relação de Benedict-Bordner* reduz o projeto do sistema a apenas um grau de liberdade ao definir o ganho g para atingir a suavização desejada, o valor de h é automaticamente determinado para garantir que o sistema recupere o rastreamento da manobra no menor tempo possível, sem oscilações indesejadas.

3.4.1.2.1 Filtro Criticamente Amortecido

O desenvolvimento das equações de rastreamento baseia-se na busca por uma formulação que seja, ao mesmo tempo, intuitiva e estatisticamente otimizada. Parte-se, inicialmente, da ideia de ajustar uma trajetória a um conjunto de medições discretas, com o objetivo de estimar a posição futura de um alvo em instantes subsequentes. Uma abordagem direta para esse problema consiste no ajuste linear por mínimos quadrados, no qual se determina a reta que melhor representa o comportamento dos dados ao minimizar a soma dos quadrados dos erros entre as medições e as estimativas do modelo (BROOKNER, 1998).

Matematicamente, define-se o erro de medição no instante n como:

$$\varepsilon_n = x_n^* - y_n, \tag{3.17}$$

em que x_n^* representa a estimativa fornecida pelo modelo e y_n a observação realizada. O critério de otimização consiste em minimizar o erro acumulado dado por:

$$e_T = \sum_{n=0}^{N} (x_n^* - y_n)^2. \tag{3.18}$$

Entretanto, a aplicação direta desse método em sistemas em tempo real apresenta uma limitação relevante: todas as medições são ponderadas de forma equivalente, independentemente de sua recência. Em cenários nos quais o alvo apresenta mudanças de dinâmica ou realiza manobras, observações antigas podem prejudicar a qualidade da predição, introduzindo atraso na resposta do sistema (BROOKNER, 1998).

Para contornar esse problema e introduzir adaptabilidade ao modelo, incorpora-se um fator de esquecimento θ, com $0 \leq \theta \leq 1$, que reduz progressivamente a influência de erros passados e privilegia medições mais recentes. Nesse contexto, o erro total passa a ser expresso como uma soma ponderada:

$$e_D = \sum_{r=0}^{N} \theta^r \, \varepsilon_{n-r}^2. \tag{3.19}$$

Esse procedimento, conhecido como mínimos quadrados com fator de desconto ao denominado *Critically Damped Filter* (CDF), introduz um mecanismo de esquecimento exponencial que atribui maior peso às medições mais recentes, permitindo que o estimador acompanhe mais rapidamente variações na trajetória, sem comprometer a consistência estatística da formulação. Embora essa abordagem seja estatisticamente ótima, sua formulação direta implicaria, em princípio, a necessidade de processamento de todo o histórico de medições a cada atualização, o que seria inviável em aplicações de tempo real. Entretanto, esse estimador pode ser reescrito exatamente como um filtro recursivo do tipo *g-h* com parâmetros constantes (BROOKNER, 1998).

A equivalência é obtida ao relacionar os parâmetros do filtro ao fator de desconto θ, resultando em:

$$g = 1 - \theta^2, \tag{3.20}$$

$$h = (1 - \theta)^2. \tag{3.21}$$

Essa equivalência é particularmente relevante em sistemas de engenharia, pois implica que toda a informação necessária sobre o passado do sistema pode ser condensada nas estimativas atuais de posição e velocidade. Dessa forma, elimina-se a necessidade de armazenamento completo do histórico de medições, viabilizando uma implementação recursiva eficiente em tempo real (BROOKNER, 1998).

3.4.1.3 Filtro de Kalman

O filtro de Kalman (KF) é um dos algoritmos de estimação mais difundidos, sendo amplamente aplicado em diversas áreas. Para a aplicação no rastreamento do movimento voluntário, o sistema deve primeiro ser modelado no espaço de estados. Como o movimento voluntário é representado por um modelo cinemático considerando a posição e sua derivada, o vetor de estados $\mathbf{x}_k$ é composto pela variável a ser estimada e sua velocidade (GALLEGO et al., 2010), sendo definido por:

$$\mathbf{x}_k = \begin{bmatrix} p_k \\ v_k \end{bmatrix} \tag{3.22}$$

onde p_k representa a posição (movimento voluntário a ser estimado) e v_k a sua velocidade. O modelo dinâmico do sistema e o modelo de medição são descritos pelas seguintes equações lineares:

$$\mathbf{x}_k = \mathbf{A}\mathbf{x}_{k-1} + \mathbf{w}_{k-1} \tag{3.23}$$

$$z_k = \mathbf{H}\mathbf{x}_k + v_k \tag{3.24}$$

onde $\mathbf{w}_{k-1}$ representa o vetor de ruído do processo e v_k é o ruído de medição. As matrizes de transição de estado ($\mathbf{A}$) e de observação ($\mathbf{H}$) são definidas por:

$$\mathbf{A} = \begin{bmatrix} 1 & T_s \\ 0 & 1 \end{bmatrix} \tag{3.25}$$

$$\mathbf{H} = \begin{bmatrix} 1 & 0 \end{bmatrix} \tag{3.26}$$

As matrizes de covariância dos ruídos são definidas levando em conta as seguintes considerações:

1. **Covariância do ruído de medição (R)**: Esse valor reflete a incerteza dos sensores associada ao ruído v_k. No contexto de supressão de tremor, a interferência é modelada como ruído branco gaussiano, onde $\mathbf{R} \approx \sigma^2_{\text{tremor}}$, representando a variância calculada a partir da densidade espectral de potência do tremor característico do paciente.

2. **Covariância do ruído do processo (Q)**: As mudanças no movimento voluntário devido ao tremor estão relacionadas ao ruído do processo $\mathbf{w}_k$ (BAR-SHALOM; LI, 1998). Utilizando um modelo de aceleração constante, a matriz assume a forma:

$$\mathbf{Q} = \sigma_v^2 \begin{bmatrix} \frac{T_s^4}{4} & \frac{T_s^3}{2} \\ \frac{T_s^3}{2} & T_s^2 \end{bmatrix} \tag{3.27}$$

   onde σ_v é o desvio padrão do componente aleatório (sendo σ_v^2 a sua variância).

Uma vez definido o modelo, o algoritmo do filtro de Kalman opera de forma recursiva a cada instante de tempo k, dividindo-se em duas etapas principais: a **Predição** (atualização no tempo) e a **Correção** (atualização da medição).

Na etapa de predição, a estimativa do estado ($\hat{\mathbf{x}}_k^-$) e a matriz de covariância do erro ($\mathbf{P}_k^-$) são projetadas um passo à frente no tempo:

$$\hat{\mathbf{x}}_k^- = \mathbf{A}\hat{\mathbf{x}}_{k-1} \tag{3.28}$$

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \tag{3.29}$$

Na etapa de correção, a nova medição z_k (proveniente dos sensores) é incorporada para refinar a estimativa anterior. Primeiramente, calcula-se o Ganho de Kalman ($\mathbf{K}_k$), seguido pela atualização do estado estimado e da covariância do erro:

$$\mathbf{K}_k = \mathbf{P}_k^-\mathbf{H}^T(\mathbf{H}\mathbf{P}_k^-\mathbf{H}^T + \mathbf{R})^{-1} \tag{3.30}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k(z_k - \mathbf{H}\hat{\mathbf{x}}_k^-) \tag{3.31}$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k\mathbf{H})\mathbf{P}_k^- \tag{3.32}$$

onde $\mathbf{I}$ é a matriz identidade. Dessa forma, o filtro pondera a confiabilidade entre a predição do modelo e a medição real do sensor para fornecer a estimativa ótima do movimento.

3.4.2 Estimação do Tremor

A modelagem do tremor pode ser realizada por meio de uma série de Fourier com parâmetros variantes no tempo, os quais são estimados de forma recursiva a fim de acompanhar

as características não estacionárias do sinal. A adaptação desses parâmetros ao sinal de entrada pode ser conduzida utilizando o algoritmo Mínimos Quadrados ou Least Mean Squares (LMS), proposto por Bernard Widrow, que se baseia em um processo iterativo de minimização do erro quadrático médio (WIDROW et al., 1975).

Por se tratar de um método baseado em gradiente, cuja atualização depende de uma estimativa instantânea do erro, o desempenho do LMS pode ser prejudicado pela presença de movimentos voluntários de alta energia. Dessa forma, torna-se necessário realizar previamente a remoção dessas componentes, de modo a garantir uma estimação mais precisa do tremor (GALLEGO et al., 2010).

Neste contexto, são avaliados dois algoritmos desenvolvidos especificamente para o rastreamento de tremores fisiológicos, bem como um filtro de Kalman proposto para a estimação da amplitude do tremor. Essa variável é particularmente relevante por apresentar maior variabilidade durante a execução de tarefas, enquanto a frequência do tremor tende a permanecer dentro de uma faixa limitada, tipicamente em torno de ±1,5 Hz em relação ao seu valor nominal (GALLEGO et al., 2010).

3.4.3 Combinador Linear de Fourier com Frequência Ponderada, Combinador Linear de Fourier Múltiplo com Banda Limitada e Filtro de Kalman

- **Combinador Linear de Fourier com Frequência Ponderada:** Conhecido como WFLC (*Weighted Frequency Fourier Linear Combiner*), é um dos modelos mais utilizados para cancelamento de ruído. Trata-se de uma extensão do algoritmo de mínimos quadrados, cuja principal característica é a capacidade de rastrear recursivamente a frequência do sinal de entrada. Além disso, o WFLC ajusta em tempo real seus parâmetros (amplitude, frequência e fase) permitindo uma modelagem adaptativa eficiente do sinal (RIVIERE; THAKOR, 1996; VAZ; KONG; THAKOR, 1994).

$$x_k = \begin{cases} \sin(rk\omega_0 t), & 1 \leq r \leq M \\ \cos(rk\omega_0 t), & M+1 \leq r \leq 2M \end{cases} \tag{3.33}$$

$$\varepsilon_k = s_k - \mathbf{W}_k^T \mathbf{X}_k - \mu_b \tag{3.34}$$

$$\omega_{0,k+1} = \omega_{0,k} + 2\mu_0 \varepsilon_k \sum_{r=1}^{M} r \left(w_{r,k} x_{M+r,k} - w_{M+r,k} x_{r,k} \right) \tag{3.35}$$

$$\mathbf{W}_{k+1} = \mathbf{W}_k + 2\mu_1 \varepsilon_k \mathbf{X}_k \tag{3.36}$$

A Equação (3.31) descreve os termos senoidais variantes no tempo da série de Fourier. A Equação (3.32) define o erro a ser minimizado pelo algoritmo LMS. Já as equações (3.33) e (3.34) correspondem aos mecanismos de adaptação da frequência e da amplitude, respectivamente.

Os principais parâmetros do algoritmo são: o número de harmônicos do modelo (M), os ganhos de adaptação de frequência (μ_0) e de amplitude (μ_1), além do termo de polarização (μ_b), utilizado para compensar componentes de baixa frequência e erros residuais. Em aplicações de cancelamento de tremor, é comum adotar $M = 1$, assumindo o tremor como predominantemente senoidal. Os demais parâmetros (μ_0, μ_1 e μ_b) são ajustados empiricamente, de modo a equilibrar a rapidez de convergência e a estabilidade da estimativa diante das variações do sinal (RIVIERE; THAKOR, 1996; ROCON, 2006).

- **Combinador Linear de Fourier Múltiplo com Banda Limitada):**

  O *Band-limited Multiple Fourier Linear Combiner* (BMFLC), ou Combinador Linear de Fourier Múltiplo com Banda Limitada, constitui uma extensão do combinador linear de Fourier desenvolvida para superar as limitações observadas no WFLC. O FLC (*Fourier Linear Combiner*) é um algoritmo adaptativo baseado na representação de sinais periódicos por meio de uma série de Fourier, no qual o sinal é aproximado como uma combinação linear de funções seno e cosseno com uma frequência fundamental previamente definida. Nesse método, os coeficientes associados a cada componente harmônica são ajustados iterativamente, geralmente por meio do algoritmo MQ, de modo a minimizar o erro entre o sinal estimado e o sinal observado (VELUVOLU et al., 2007).

  A proposta do BMFLC é melhorar o desempenho em situações nas quais o sinal (como o tremor patológico) apresenta múltiplas componentes espectrais relevantes ou sofre variações rápidas de frequência ao longo do tempo. Diferentemente do WFLC, que ajusta explicitamente a frequência, o BMFLC utiliza uma estrutura composta por vários FLCs operando em paralelo. Cada um desses filtros é associado a uma frequência previamente fixada dentro de uma faixa de interesse, sendo responsável por adaptar apenas a sua amplitude de acordo com o sinal de entrada. O funcionamento do método baseia-se na definição de uma banda de frequências delimitada por um valor inferior ω_0 e um superior ω_f. Dentro deste intervalo, são distribuídos G filtros, formando um banco de FLCs igualmente espaçados no domínio da frequência. A base harmônica x_k utilizada na aproximação do sinal é expressa por (VELUVOLU et al., 2007):

$$x_k = \begin{cases} \sin\left(\omega_0 + (r-1)\frac{\omega_f - \omega_0}{G+1}\right)k, & 1 \leq r \leq M \\ \cos\left(\omega_0 + (r-M-1)\frac{\omega_f - \omega_0}{G+1}\right)k, & M+1 \leq r \leq 2M \end{cases} \tag{3.37}$$

  O processo adaptativo baseia-se na minimização do erro ε_k e na atualização iterativa do vetor de pesos $\mathbf{W}_k$, conforme as equações abaixo:

$$\varepsilon_k = s_k - \mathbf{W}_k^T \mathbf{X}_k - \mu_b \tag{3.38}$$

$$\mathbf{W}_{k+1} = \mathbf{W}_k + 2\mu\varepsilon_k \mathbf{X}_k \tag{3.39}$$

Nestas expressões, $\mathbf{X}_k$ representa o vetor da base harmônica, ε_k é a diferença entre o sinal observado s_k e a sua estimativa, e os coeficientes $\mathbf{W}_k$ ajustam as amplitudes de cada componente de frequência. O termo μ_b é uma componente de polarização (*bias*), responsável por compensar desvios de baixa frequência no sinal(RIVIERE; RADER; THAKOR, 1998).

O desempenho do BMFLC é sensível à escolha dos seus parâmetros, nomeadamente:

- M: o número de harmônicas em cada FLC;
- μ: o ganho de adaptação;
- ω_0 e ω_f: os limites inferior e superior da banda;
- G: a quantidade de filtros intermediários no banco.

Embora não tenha sido originalmente formulado como um estimador de frequência, o BMFLC permite inferir a frequência instantânea do sinal através da contribuição relativa de cada componente. Esta estimativa pode ser obtida por meio de uma média ponderada das frequências associadas a cada FLC, onde os pesos são dados pelas amplitudes estimadas. Para o caso de uma série de Fourier de primeira ordem, tem-se (GALLEGO et al., 2010):

$$\omega_k = \frac{\sum_{r=0}^{L}(a_r^2 + b_r^2)\omega_r}{\sum_{r=0}^{L}(a_r^2 + b_r^2)} \tag{3.40}$$

onde:

- ω_k representa a estimativa da frequência instantânea predominante do sinal no instante discreto k;
- L é o número total de componentes em frequência (osciladores) que compõem o banco de filtros do BMFLC;
- r é o índice que denota cada componente individual dentro do banco de filtros;
- ω_r corresponde à frequência de referência fixa associada ao r-ésimo componente do filtro;
- a_r e b_r são, respectivamente, as amplitudes dinâmicas estimadas para os termos cosseno e seno do r-ésimo componente da série de Fourier.

Nesta formulação matemática, o termo $(a_r^2 + b_r^2)$ representa o quadrado da magnitude (proporcional à potência) de cada componente de frequência. O algoritmo utiliza esse valor como peso na média ponderada. Consequentemente, os componentes de frequência ω_r que apresentam maior amplitude exercem maior influência sobre o resultado do somatório, conduzindo a estimativa final ω_k para a frequência real de oscilação do tremor.

- **Filtro de Kalman (KF):** Os algoritmos WFLC e BMFLC realizam a adaptação ao sinal de entrada a partir de estimativas específicas do gradiente. Em contraste, o filtro de Kalman (KF) é conhecido por fornecer uma solução ótima para problemas de estimação, pois minimiza a covariância do erro a posteriori. Dessa forma, o desempenho desses algoritmos, especialmente na estimação da amplitude, pode ser aprimorado com o uso de um KF adequadamente projetado (GALLEGO et al., 2010).

  Fundamentalmente, o KF resolve um problema de estimação de estados com base na estrutura de um observador de Luenberger. Para compreender essa formulação, considera-se um sistema dinâmico genérico no tempo discreto, sujeito a ruídos estocásticos:

$$\mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k + \mathbf{B}\mathbf{u}_k + \mathbf{w}_k \tag{3.41}$$

$$\mathbf{y}_k = \mathbf{C}\mathbf{x}_k + \mathbf{v}_k \tag{3.42}$$

  em que $\mathbf{w}_k$ e $\mathbf{v}_k$ representam, respectivamente, os vetores de perturbações (ruídos de processo e de medição), assumidos como processos Gaussianos de média nula e matrizes de covariância $\mathbf{Q}$ e R. A estrutura do observador busca estimar o estado atualizado a partir da seguinte lei de atualização:

$$\hat{\mathbf{x}}_{k+1} = \mathbf{A}\hat{\mathbf{x}}_k + \mathbf{B}\mathbf{u}_k + \mathbf{L}(\mathbf{y}_k - \hat{\mathbf{y}}_k) \tag{3.43}$$

  em que $\mathbf{L}$ é o ganho de Kalman, $\hat{\mathbf{x}}_k$ é o vetor de estado estimado e $\hat{\mathbf{y}}_k = \mathbf{C}\hat{\mathbf{x}}_k$ é o vetor de saídas estimado. O objetivo é calcular de forma ótima o ganho $\mathbf{L}$ para fazer $\hat{\mathbf{y}}_k$ convergir para a medição $\mathbf{y}_k$, resolvendo o problema de determinar o estado desconhecido $\mathbf{x}_k$.

  Aplicando essa base teórica ao problema de estimação do tremor, define-se o modelo específico no espaço de estados. Neste caso, o modelo do sinal não possui uma entrada de controle explícita ($\mathbf{B} = \mathbf{0}$) e adota-se a matriz de observação denotada por $\mathbf{H}$ (equivalente a $\mathbf{C}$). O vetor de estados $\mathbf{x}_k$ é composto pela frequência instantânea (ω_0), pelas amplitudes dos termos senoidais da série de Fourier de primeira ordem (a e b) e pela estimativa do sinal de tremor (s_{tr}):

$$\mathbf{x}_k = \begin{bmatrix} \omega_{0,k} \\ a_k \\ b_k \\ s_{tr,k} \end{bmatrix} \tag{3.44}$$

Considerando que a frequência do tremor varia lentamente, tipicamente dentro de uma faixa de $\pm 1{,}5$ Hz em torno de uma frequência característica do paciente, a estimação dessa frequência é realizada por meio do WFLC. Assim, adota-se uma estrutura em cascata, na qual o WFLC rastreia a frequência e fornece essa informação ao KF, que assume a responsabilidade pela estimação da amplitude (GALLEGO et al., 2010). A matriz de transição de estados (**A**) e a matriz de observação (**H**) são definidas como:

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & \cos(\omega_{0,k}) & \sin(\omega_{0,k}) & 0 \end{bmatrix} \tag{3.45}$$

$$\mathbf{H} = \begin{bmatrix} 0 & 0 & 0 & 1 \end{bmatrix} \tag{3.46}$$

As matrizes de covariância dos ruídos são definidas da seguinte forma:

- A covariância do ruído de medição é um escalar dado por $R = \sigma_{tr}^2$, exercendo pouca influência na duração do regime transitório.
- A matriz de covariância do ruído de processo é definida como $\mathbf{Q} = \text{diag}(q_{1,1}, q_{2,2}, q_{3,3}, q_{4,4})$, assumindo independência entre as variáveis de estado.

Com a estrutura do sistema estabelecida, o algoritmo do filtro de Kalman opera recursivamente. A etapa de **Predição** projeta o estado estimado ($\hat{\mathbf{x}}_k^-$) e a matriz de covariância do erro ($\mathbf{P}_k^-$) um passo à frente no tempo:

$$\hat{\mathbf{x}}_k^- = \mathbf{A}\hat{\mathbf{x}}_{k-1} \tag{3.47}$$

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \tag{3.48}$$

Na etapa de **Correção**, a medição real y_k é incorporada. O filtro calcula o Ganho de Kalman ($\mathbf{K}_k$) e atualiza as estimativas de estado e covariância:

$$\mathbf{K}_k = \mathbf{P}_k^-\mathbf{H}^T(\mathbf{H}\mathbf{P}_k^-\mathbf{H}^T + R)^{-1} \tag{3.49}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k(y_k - \mathbf{H}\hat{\mathbf{x}}_k^-) \tag{3.50}$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k\mathbf{H})\mathbf{P}_k^- \tag{3.51}$$

onde $\mathbf{I}$ representa a matriz identidade de ordem 4.

- **Erro de Rastreamento Cinemático:**

  Embora originalmente concebido para quantificar a energia do tremor (**??**), nesta etapa da pesquisa, o KTE é aplicado para avaliar a fidelidade do rastreamento do algoritmo de

estimativa de movimento voluntário. Essa métrica permite quantificar simultaneamente a suavidade do sinal e o tempo de resposta do algoritmo (GALLEGO et al., 2010).

Matematicamente, o KTE é definido por:

$$I_{KTE} = \sqrt{\phi^2_{|b^*|} + \sigma^2_{|b^*|}} \tag{3.52}$$

onde $\phi_{|b^*|}$ e $\sigma^2_{|b^*|}$ representam, respectivamente, a média e a variância do erro absoluto de estimativa, sendo a variável auxiliar definida como $b^* = |y_k - x_{k+1,k}|$. A interpretação física desses componentes é fundamental para o ajuste do controlador:

- **Componente da média** (ϕ): Penaliza o atraso do filtro, indicando quão rápido o algoritmo reage a mudanças de velocidade no movimento voluntário.
- **Componente da variância** (σ^2): Quantifica a suavidade da variável estimada, indicando a capacidade do filtro de rejeitar as oscilações de alta frequência características do tremor patológico.

- **Erro Quadrático Médio Fracionário:**

  A adoção do Erro Quadrático Médio Filtrado com compensação de atraso (*Filtered Mean Square Error with delay correction* — FMSEd) neste trabalho justifica-se pelas limitações intrínsecas da Raiz do Erro Quadrático Médio (*Root Mean Square Error* — RMSE). Embora amplamente difundido na literatura, o RMSE apresenta sensibilidade elevada a erros de grande magnitude, como os provenientes de *overshoots* e *undershoots*. Tal característica pode mascarar discrepâncias sutis, porém relevantes, entre o sinal estimado e o de referência (GONZALEZ et al., 2000).

  Ademais, o RMSE é extremamente sensível a defasagens temporais. Estimativas que preservam a forma e a amplitude do sinal original podem ser severamente penalizadas caso haja o mínimo atraso entre as séries. Para mitigar esse problema, o FMSEd surge como uma alternativa robusta, fundamentada na estimação e correção do atraso instantâneo entre o sinal de referência e o estimado. Esse alinhamento temporal prévio permite o cálculo de uma métrica de erro mais representativa da fidelidade da estimativa (GONZALEZ et al., 2000).

  A formulação do FMSEd para um instante k pode ser expressa matematicamente pela Equação 3.53:

$$I_{FMSEd_k} = \sqrt{E\left[(s_k - t_{k-\hat{d}_k})^2\right]} \tag{3.53}$$

  em que s_k representa o sinal de referência (tremor), $t_{k-\hat{d}_k}$ corresponde ao sinal estimado devidamente compensado pelo atraso, e $\hat{d}_k$ denota o atraso instantâneo estimado. Este último é comumente obtido através de algoritmos adaptativos que minimizam o erro

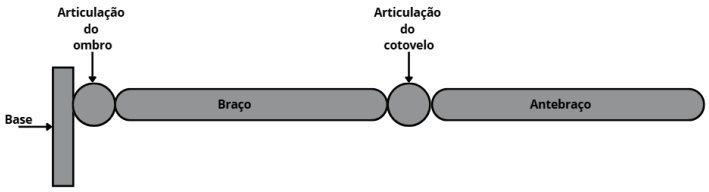
quadrático, como os métodos baseados em *Least Mean Squares* (LMS) (ETTER; STEARNS, 1981). Especificamente neste trabalho, a atualização iterativa de $\hat{d}_k$ ocorre a cada amostra ajustando-se o atraso anterior em função do erro de alinhamento instantâneo e do gradiente (derivada) do sinal estimado, ponderados por um passo de adaptação. Ademais, para compensar atrasos fracionários que não coincidem com múltiplos exatos do período de amostragem, o algoritmo emprega uma interpolação linear entre amostras adjacentes, garantindo um alinhamento temporal fino.

3.5 Experimento de Bancada

3.5.1 Reprodução do Temor na Estrutura da Manivela Deslizante

A estrutura utilizada para a geração de tremores consiste em um mecanismo de manivela deslizante (*slider-crank*), projetado para converter o movimento rotativo em oscilações lineares com frequências controladas. Este sistema baseia-se em um manipulador mecânico desenvolvido para representar, de forma simplificada, a biomecânica do membro superior humano, simulando especificamente as articulações do ombro e do cotovelo. A estrutura é composta por dois elos rígidos que personificam o braço e o antebraço, conforme demonstrado na Figura 17 (ZUBAIR; SUTHAR; JUNG, 2022).

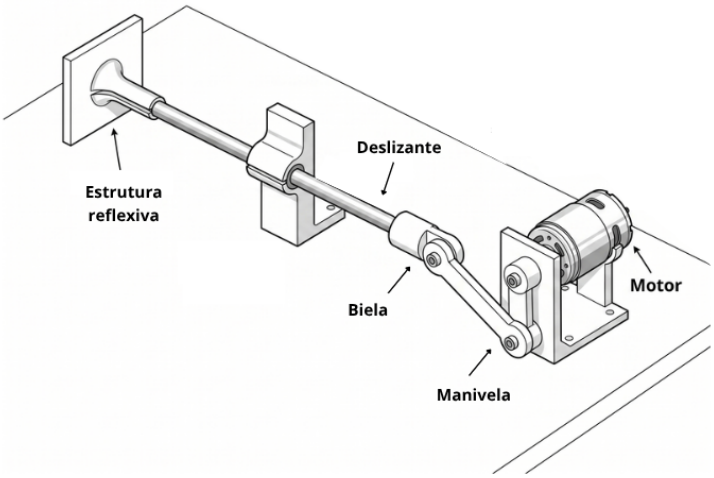
Figura 17 Modelo com o mecanismo de dois apoios para representação biomecânica.



Fonte: Adaptado de ZUBAIR; SUTHAR; JUNG, 2022.

O *setup* experimental é composto por uma manivela (*crank*), uma biela (*connecting rod*) e um cursor deslizante, que atuam em conjunto para replicar o comportamento dinâmico do tremor na estrutura do braço projetado. Na ponta do deslizante existe uma estrutura quadrada reflexiva que tem como objetivo diminuir o ruído das leituras do sensor. Este modelo, ilustrado na Figura 18, utiliza comprimentos segmentares estipulados para cada membro, permitindo uma simulação antropométrica ao sinal de referência (ZUBAIR; SUTHAR; JUNG, 2022).

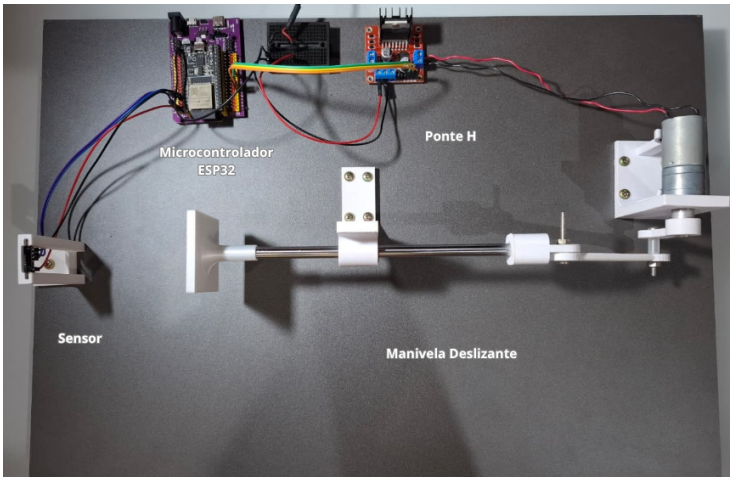
Figura 18 Modelo projetado para a representação mecânica do braço.



Fonte: Autoria própria

A reprodução mecânica do distúrbio fundamenta-se na etapa de estimação realizada previamente. O sinal de tremor estimado é processado por um microcontrolador ESP32, responsável por comandar um motor CC acoplado ao mecanismo por meio de um driver de potência do tipo Ponte H. Essa conFiguração possibilita que o motor reproduza as oscilações patológicas, acionando a manivela com a dinâmica requerida através da técnica de Modulação por Largura de Pulso, do inglês *Pulse Width Modulation* (PWM). O sistema desenvolvido encontra-se ilustrado na Figura 19.

Figura 19 Sistema que produz o tremor Parkinsoniano



Fonte: Autoria própria

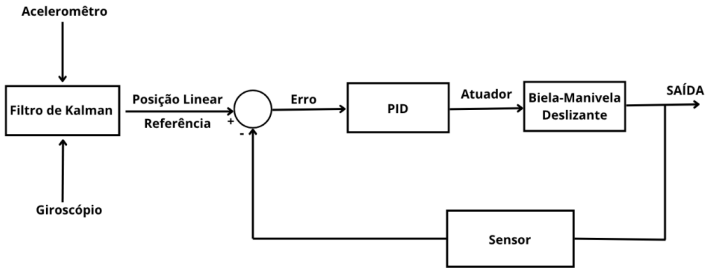
3.5.2 Controle de Posição para Reprodução do Tremor Estimado

O experimento, até esta etapa, utilizou exclusivamente os dados do giroscópio para mitigar o efeito de drift e garantir a máxima fidelidade na estimação do tremor. Contudo, para estimar a posição real a ser reproduzida pelo modelo, é necessário fundir os dados do giroscópio

com os do acelerômetro por meio do filtro de Kalman, viabilizando o cálculo do deslocamento linear a ser seguido.

Uma vez determinada a trajetória de referência, será aplicado um controle Proporcional-Integral-Derivativo (PID) para que o braço busque alcançar a posição desejada. A malha de realimentação do PID utilizará um sensor de distância a laser para monitorar, em tempo real, a posição atual do braço e corrigir eventuais desvios. O diagrama de blocos que representa a malha de controle está ilustrado na Figura 20.

Figura 20 Diagrama de blocos do Controle de Posição.



Fonte: Autoria própria

A estratégia de processamento de sinais e controle da bancada seguirá as etapas descritas a seguir:

- **Processamento dos dados do giroscópio:** Os dados de velocidade angular serão processados pelos algoritmos de melhor performance identificados nas etapas anteriores para o rastreio do movimento voluntário e a estimativa do tremor. Por medir diretamente a taxa de rotação, o giroscópio fornece a dinâmica principal para a reprodução do movimento.

- **Filtragem do dados do acelerômetro:** Diferente da abordagem preditiva usada no giroscópio, o sinal do acelerômetro será submetido a um filtro passa-banda com frequências de corte entre 4 Hz e 15 Hz que é a faixa de frequência do tremor Parkinsoniano (repouso e ação) (MENDONCA et al., 2024). Esta etapa visa isolar exclusivamente as oscilações mecânicas associadas ao tremor, descartando as componentes de baixa frequência que induzem erros de integração (*drift*) e a aceleração gravitacional.

- **Fusão Sensorial via Filtro de Kalman:** Para obter uma estimativa de posição linear precisa e estável, será implementada uma fusão sensorial utilizando o filtro de Kalman. Este algoritmo combinará a dinâmica rápida do giroscópio com a referência oscilatória do acelerômetro filtrado, resultando em um sinal de posição otimizado para o controle da bancada.

  A formulação empregada baseia-se no modelo clássico de espaço de estados apresentado em trabalhos de estimação de atitude e fusão sensorial utilizando IMUs (MACHADO, 2023). Nesse contexto, o filtro de Kalman atua como um estimador recursivo capaz de

combinar medições ruidosas provenientes de sensores distintos, levando em consideração suas respectivas incertezas estatísticas.

No modelo adotado, o vetor de estados é definido por:

$$\mathbf{x}_k = \begin{bmatrix} p_k \\ v_k \end{bmatrix} \tag{3.54}$$

onde p_k representa a posição linear estimada e v_k a velocidade linear do sistema.

A dinâmica do sistema é modelada assumindo movimento uniformemente acelerado, sendo descrita pela equação discreta de estados:

$$\mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k + \mathbf{B}\mathbf{u}_k + \mathbf{w}_k \tag{3.55}$$

em que $\mathbf{u}_k$ corresponde à aceleração medida pelo acelerômetro no instante atual, enquanto $\mathbf{w}_k$ representa o ruído de processo associado às incertezas do modelo dinâmico.

As matrizes do sistema foram definidas como:

$$\mathbf{A} = \begin{bmatrix} 1 & T_s \\ 0 & 1 \end{bmatrix} \tag{3.56}$$

e

$$\mathbf{B} = \begin{bmatrix} \frac{1}{2}T_s^2 \\ T_s \end{bmatrix} \tag{3.57}$$

sendo T_s o período de amostragem do sistema.

A etapa de medição utiliza como referência a velocidade angular proveniente do giroscópio, convertida para velocidade linear através do raio efetivo do mecanismo. Dessa forma, o modelo de medição é definido por:

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \tag{3.58}$$

com a matriz de observação sendo:

$$\mathbf{H} = \begin{bmatrix} 0 & 1 \end{bmatrix} \tag{3.59}$$

onde $\mathbf{v}_k$ representa o ruído associado à medição do giroscópio.

A etapa de predição do filtro projeta o estado e a covariância um passo à frente no tempo, utilizando a aceleração recém-adquirida:

$$\hat{\mathbf{x}}_k^- = \mathbf{A}\hat{\mathbf{x}}_{k-1} + \mathbf{B}\mathbf{u}_{k-1} \tag{3.60}$$

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \tag{3.61}$$

em que $\mathbf{Q}$ representa a matriz de covariância do ruído de processo, associada à confiança atribuída ao modelo dinâmico.

Na etapa de correção, o ganho de Kalman é calculado por:

$$\mathbf{K}_k = \mathbf{P}_k^-\mathbf{H}^T\left(\mathbf{H}\mathbf{P}_k^-\mathbf{H}^T + \mathbf{R}\right)^{-1} \tag{3.62}$$

onde $\mathbf{R}$ corresponde à covariância do ruído de medição, relacionada à confiança atribuída ao sinal derivado do giroscópio.

Em seguida, a estimativa de estado é corrigida incorporando a medição atual:

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k\left(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-\right) \tag{3.63}$$

Por fim, a matriz de covariância do erro a posteriori é atualizada para o próximo ciclo de iteração:

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k\mathbf{H})\mathbf{P}_k^- \tag{3.64}$$

onde $\mathbf{I}$ representa a matriz identidade. Isso permite que o sistema combine continuamente a previsão baseada no modelo dinâmico com a informação medida pelos sensores.

Após a etapa de estimação, o sinal de posição obtido ainda pode apresentar deriva residual devido à integração acumulativa inerente aos sensores inerciais. Para minimizar esse efeito, será aplicado um filtro passa-altas com frequência de corte de 0,5 Hz, removendo componentes de baixa frequência associadas ao *drift*. Em seguida, o sinal será convertido de metros para milímetros, produzindo a variável final utilizada como referência de deslocamento linear da bancada experimental.

- **Malha Fechada com Sensor a Laser:** O sinal resultante da fusão sensorial será adotado como o *setpoint* da malha de controle. A posição real do cursor na estrutura biela-manivela será monitorada por um sensor de distância a laser VL53L0X (STMicroelectronics, 2016), conFigurado em seu modo de alta velocidade para garantir uma taxa de amostragem de 50 Hz. Esse componente fornecerá o *feedback* contínuo ao microcontrolador ESP32, o qual modulará o acionamento do motor por meio de um *driver* Ponte H, com o objetivo de minimizar o erro dinâmico entre a trajetória simulada e a fisicamente executada.

- **Filtro de Kalman para Filtragem da Posição:**

  Devido à presença de ruídos inerentes ao sensor a laser, foi implementado um filtro de Kalman discreto com o objetivo de suavizar as medições de posição e melhorar a confiabilidade do sinal utilizado pelo controlador PID. A utilização direta do sinal bruto do sensor poderia introduzir oscilações indesejadas na malha de controle, especialmente na ação derivativa, tornando o sistema mais sensível a perturbações e ruídos de medição.

  O filtro foi modelado considerando um sistema linear discreto de dois estados, representados pela posição e velocidade do mecanismo (SIMON, 2006). O vetor de estados adotado é dado por:

$$\mathbf{x}_k = \begin{bmatrix} p_k \\ v_k \end{bmatrix} \tag{3.65}$$

  onde:

  - p_k representa a posição estimada do mecanismo;
  - v_k representa a velocidade estimada;
  - k representa o instante discreto de amostragem.

  O modelo de evolução temporal do sistema foi definido assumindo velocidade aproximadamente constante entre amostras consecutivas, sendo descrito por:

$$\mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k + \mathbf{w}_k \tag{3.66}$$

  com:

$$\mathbf{A} = \begin{bmatrix} 1 & T_s \\ 0 & 1 \end{bmatrix} \tag{3.67}$$

  onde Ts corresponde ao período de amostragem do sistema.

  O termo $\mathbf{w}_k$ representa o ruído de processo, associado às incertezas do modelo matemático e às variações dinâmicas não modeladas do sistema.

  A equação de medição utilizada pelo filtro é dada por:

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \tag{3.68}$$

  em que:

$$\mathbf{H} = \begin{bmatrix} 1 & 0 \end{bmatrix} \tag{3.69}$$

sendo $\mathbf{z}_k$ a medição fornecida pelo sensor VL53L0X e $\mathbf{v}_k$ o ruído associado à medição.

O algoritmo executa duas etapas principais a cada período de amostragem:

1. **Predição:** estima o próximo estado do sistema utilizando o modelo matemático;

$$\hat{\mathbf{x}}_k^- = \mathbf{A}\hat{\mathbf{x}}_{k-1} \tag{3.70}$$

bem como a matriz de covariância predita:

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \tag{3.71}$$

2. **Atualização:** corrige a estimativa utilizando a medição atual do sensor:

$$\mathbf{K}_k = \mathbf{P}_k^-\mathbf{H}^T\left(\mathbf{H}\mathbf{P}_k^-\mathbf{H}^T + \mathbf{R}\right)^{-1} \tag{3.72}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k\left(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-\right) \tag{3.73}$$

$$\mathbf{P}_k = \left(\mathbf{I} - \mathbf{K}_k\mathbf{H}\right)\mathbf{P}_k^- \tag{3.74}$$

As matrizes de covariância do ruído de processo e do ruído de medição foram ajustadas experimentalmente para equilibrar suavização e rapidez da resposta do filtro. A matriz de ruído de medição foi definida como:

$$\mathbf{R} = \begin{bmatrix} r \end{bmatrix} \tag{3.75}$$

enquanto a matriz de ruído de processo foi baseada na aceleração do sistema, sendo descrita por (BAR-SHALOM; LI; KIRUBARAJAN, 2001):

$$\mathbf{Q} = q\begin{bmatrix} \frac{T_s^4}{4} & \frac{T_s^3}{2} \\ \frac{T_s^3}{2} & T_s^2 \end{bmatrix} \tag{3.76}$$

onde q representa o parâmetro σ_v^2 associado ao ruído de aceleração do modelo.

A saída utilizada na malha de controle corresponde à posição estimada pelo filtro, reduzindo significativamente as oscilações provocadas pelo ruído do sensor. Dessa forma, o filtro de Kalman contribui para aumentar a estabilidade prática do sistema, melhorar a suavidade da resposta do controlador PID e reduzir efeitos indesejados associados à derivação numérica do sinal de erro.

- **Identificação da Dinâmica do Sistema:** Antes da implementação da malha de controle, fez-se necessário obter um modelo matemático que representasse a dinâmica da planta, composta pelo *driver* de potência, motor CC e mecanismo biela-manivela deslizante. Para isso, conduziu-se um ensaio experimental em malha aberta, no qual o sistema recebeu

excitação por um sinal PWM constante correspondente a aproximadamente 50% da capacidade nominal do atuador, partindo da condição inicial de repouso.

Durante o ensaio, registrou-se a posição do mecanismo por meio do sensor a laser, adotando uma frequência de amostragem de 50 Hz, equivalente a um período de 0,02 s. Os sinais de entrada (PWM aplicado) e de saída (posição medida) foram armazenados e posteriormente processados no *software* MATLAB.

A modelagem matemática ocorreu por meio da ferramenta *System Identification Toolbox*, responsável por estimar modelos dinâmicos a partir dos dados experimentais de entrada e saída. Essa *toolbox* utiliza algoritmos de identificação paramétrica capazes de ajustar funções de transferência que representem, da forma mais fiel possível, o comportamento observado experimentalmente.

A partir dos dados coletados, estimaram-se dois modelos discretos para retratar a dinâmica da planta. O primeiro, de concepção mais simples, apresentou dois polos e um zero, enquanto o segundo contemplou uma estrutura de maior complexidade, contendo três polos e dois zeros.

O emprego de dois modelos distintos teve como objetivo avaliar a robustez do controlador projetado. Inicialmente, o controlador PID baseado na metodologia IMC *(Internal Model Control)* ajustou-se utilizando o modelo mais simples, devido à sua menor complexidade matemática e maior facilidade de análise. Em seguida, essa mesma sintonia aplicou-se ao modelo mais complexo, o que permitiu verificar o desempenho do controle diante de uma representação mais realista da planta. Essa abordagem mostrou-se importante porque, durante a sintonia de controladores baseados em modelo, podem ocorrer cancelamentos exatos entre polos e zeros na representação matemática. Como tais cancelamentos ideais dificilmente acontecem em sistemas reais devido a incertezas paramétricas, dinâmicas não modeladas e ruídos, a validação da sintonia em um modelo mais complexo assegurou a análise da robustez do sistema frente a essas limitações práticas (SEBORG et al., 2017).

O processo de identificação de sistemas possibilitou a obtenção de uma função de transferência discreta capaz de representar adequadamente a dinâmica temporal do mecanismo. Por fim, esse modelo matemático serviu como base para a etapa de sintonia do controlador PID-IMC, viabilizando a determinação apropriada dos ganhos proporcional (k_p), integral (k_i) e derivativo (k_d).

- **Sintonia do Controlador PID-IMC:**

  Após a obtenção e validação dos modelos matemáticos da planta, será realizada a sintonia do controlador PID-IMC com o objetivo de determinar os ganhos proporcional (K_p), integral (K_i) e derivativo (K_d) mais adequados para o sistema. A sintonia IMC (Internal Model Control), também conhecida como λ-tuning, busca determinar os parâmetros do controlador PID de forma que a resposta em malha fechada apresente uma dinâmica dese-

jada, geralmente definida por um modelo de primeira ordem. Nesse método, a velocidade de resposta do sistema é ajustada pela constante de tempo τ_{MF}, também representada por λ(MORARI; ZAFIRIOU, 1989).

Neste trabalho, foi utilizada a formulação da sintonia IMC para processos de segunda ordem com atraso de transporte, representados por:

$$G(s) = k_s \frac{\omega_n^2}{s^2 + 2\zeta s + \omega_n^2} e^{-\theta s} \tag{3.77}$$

Para esse tipo de modelo, os ganhos do controlador PID são obtidos por:

$$k_p = \frac{2\zeta}{k_s \omega_n (\theta + \tau_{MF})} \tag{3.78}$$

$$k_i = \frac{k_p \omega_n}{2\zeta} \tag{3.79}$$

$$k_d = \frac{k_p}{2\zeta \omega_n} \tag{3.80}$$

onde k_s representa o ganho estático da planta, ω_n a frequência natural, ζ o coeficiente de amortecimento, θ o atraso de transporte e τ_{MF} o parâmetro responsável pela dinâmica desejada em malha fechada.

Nesta abordagem de sintonia, a estimação do modelo via métodos de inteligência computacional ocorre no domínio discreto, obtendo-se $G(z)$. Consequentemente, faz-se necessária a conversão da planta para o domínio contínuo, $G(s)$, o que viabiliza a parametrização do controlador $C(s)$. Posteriormente, o controlador projetado deve ser discretizado para $C(z)$, garantindo sua correta implementação no sistema digital.

A robustez da resposta será avaliada meio das funções de sensibilidade e sensibilidade complementar, amplamente utilizadas em análises no domínio da frequência. Essas funções permitem quantificar os efeitos de perturbações, incertezas de modelagem e ruídos sobre o desempenho do sistema em malha fechada (SKOGESTAD; POSTLETHWAITE, 2005).

A função de sensibilidade é definida por:

$$S(s) = \frac{1}{1 + L(s)} \tag{3.81}$$

enquanto a função de sensibilidade complementar é dada por:

$$T(s) = \frac{L(s)}{1 + L(s)} \tag{3.82}$$

onde $L(s)$ representa a função de transferência em malha aberta do sistema. O pico máximo da magnitude dessas funções é utilizado como índice de robustez, sendo definido respectivamente por:

$$M_s = \max |S(j\omega)| \tag{3.83}$$

$$M_t = \max |T(j\omega)| \tag{3.84}$$

O pico da função de sensibilidade M_s está associado à robustez do sistema e à rejeição de perturbações, enquanto o pico da função de sensibilidade complementar M_t relaciona-se à amplificação de ruídos e ao comportamento ressonante da malha fechada (SKOGESTAD; POSTLETHWAITE, 2005).

A partir desses índices, é possível estimar margens clássicas de estabilidade, como margem de ganho e margem de fase. A margem de ganho estimada pode ser calculada por (SILVEIRA et al., 2025):

$$I_{GM_{dB}} \geq \min\left(20\log_{10}\left(\frac{M_s}{M_s-1}\right), 20\log_{10}\left(1+\frac{1}{M_t}\right)\right) \tag{3.85}$$

enquanto a margem de fase estimada é dada por:

$$I_{PM} \geq \frac{180}{\pi}\min\left(2\arcsin\left(\frac{1}{2M_s}\right), 2\arcsin\left(\frac{1}{2M_t}\right)\right) \tag{3.86}$$

Essas expressões fornecem aproximações pessimistas das margens de estabilidade do sistema, sendo amplamente utilizadas em sintonias de controle robusto. O uso do operador mínimo nas equações garante que a análise considere a condição mais crítica de estabilidade (SILVEIRA et al., 2025).

Valores elevados das margens de ganho (MG) e de fase (MF) geralmente estão associados a sistemas mais robustos, porém com respostas mais conservadoras e menor desempenho dinâmico. Por outro lado, margens reduzidas podem proporcionar respostas mais rápidas, embora aumentem a sensibilidade da malha a incertezas e diminuam sua robustez (SILVEIRA et al., 2025). Para que o sistema de controle apresente estabilidade robusta e desempenho adequado, normalmente busca-se uma margem de fase entre 30° e 60° e uma margem de ganho entre 6 dB e 15 dB. Nessas condições, o sistema tende a suportar melhor perturbações e variações paramétricas, mantendo a estabilidade da malha fechada (STEVENS; LEWIS; JOHNSON, 2016).

- **Implementação Experimental:**

  Após as etapas de identificação da planta, sintonia do controlador PID e definição das técnicas de filtragem e condicionamento de sinal, será desenvolvida a implementação experimental completa do sistema de controle em tempo discreto utilizando o microcontrolador ESP32.

O algoritmo será estruturado em linguagem C++ no ambiente Arduino IDE, integrando o sensor a laser VL53L0X no modo de alta velocidade, a ponte H responsável pelo acionamento do motor CC e o controlador PID digital. A comunicação com o sensor será realizada por meio do protocolo I^2C (*Inter-Integrated Circuit*), utilizando os pinos SDA (*Serial Data Line*) e SCL (*Serial Clock Line*) do ESP32.

O sistema operará com período de amostragem fixo de:

$$T_s = 20 \text{ ms} \tag{3.87}$$

equivalente a uma frequência de amostragem de:

$$f_s = 50 \text{ Hz} \tag{3.88}$$

garantindo sincronismo entre a aquisição dos dados, a atualização do filtro de Kalman e a execução da lei de controle digital.

Inicialmente, durante a etapa de inicialização, será realizada uma calibração automática da posição de referência do sensor. Nesse procedimento, múltiplas amostras serão coletadas durante aproximadamente cinco segundos para calcular a média inicial da distância medida, definindo assim o ponto de referência zero do sistema mecânico.

Após a calibração, o programa executará continuamente um laço de controle discreto composto pelas seguintes etapas:

1. Leitura da posição medida pelo sensor VL53L0X;
2. Aplicação do filtro de Kalman para redução dos ruídos de medição e estimação da posição e velocidade do mecanismo;
3. Atualização do sinal de referência armazenado no vetor discreto;
4. Cálculo do erro de controle:

$$e(k) = r(k) - y(k) \tag{3.89}$$

   onde:

   - $r(k)$ representará a referência desejada;
   - $y(k)$ representará a posição estimada pelo filtro.

5. Aplicação da lei de controle PID IMC;
6. Conversão do sinal de controle em comando PWM para acionamento do motor.

Além do controlador PID, serão implementadas estratégias adicionais para aumentar a estabilidade prática e preservar os componentes eletromecânicos do sistema:

- **Zona morta (*Deadband*):** será utilizada para desligar o motor quando o erro permanecer dentro de uma faixa de tolerância próxima da referência, reduzindo oscilações de alta frequência e desgaste mecânico;
- **Anti-windup:** será aplicado para limitar o crescimento excessivo do termo integral;
- **Saturação do PWM:** restringirá o sinal de acionamento aos limites operacionais do motor;
- **Controle bidirecional:** será realizado pela ponte H, permitindo a inversão do sentido de rotação conforme o sinal de controle calculado.

O sinal PWM será gerado utilizando os periféricos internos do ESP32 com resolução de 11 bits e frequência de 500 Hz, permitindo maior precisão no acionamento do motor CC.

Durante a execução experimental, os dados de tempo, posição bruta medida pelo sensor, posição filtrada pelo filtro de Kalman, sinal de controle, valor PWM aplicado e referência serão enviados via comunicação serial para aquisição e posterior análise no MATLAB. Essa estratégia permitirá avaliar o desempenho do sistema em termos de rastreamento de referência, estabilidade, rejeição de ruídos e comportamento transitório da malha de controle.

4 RESULTADOS E DISCUSSÃO

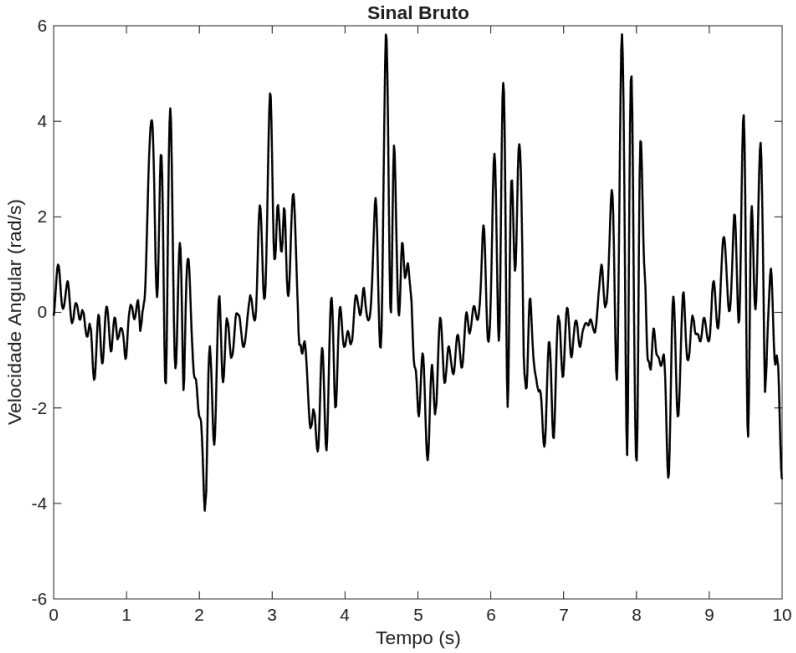
Estruturada em três etapas, a análise inicia-se pela caracterização do sinal bruto em ambiente simulado. Posteriormente, aplica-se a metodologia de separação de componentes para isolar o movimento voluntário do tremor. O ciclo encerra-se com a implementação em bancada, onde o sistema físico reproduz o tremor previamente estimado.

4.1 Caracterização do Sinal

O sinal bruto, correspondente ao eixo x do giroscópio durante a execução da tarefa, é apresentado na Figura 21. Observa-se que este sinal apresenta uma amplitude máxima de 6 rad/s ao longo de 10 segundos de duração.

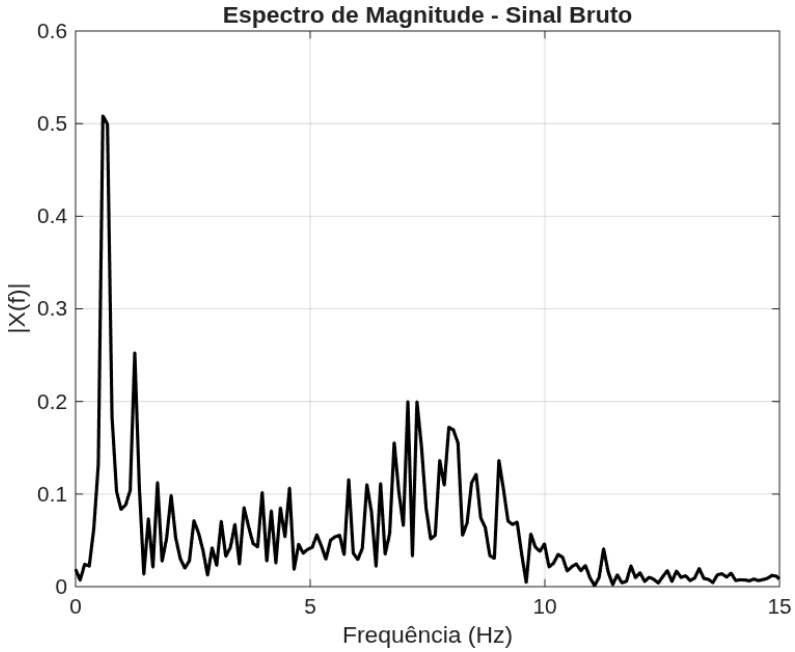
A representação no domínio da frequência deste sinal, obtida via Transformada de Fourier (FFT), é mostrada na Figura 22. Na análise espectral, é possível notar um pico de frequência proeminente entre 1 e 2 Hz, seguido por picos adicionais em frequências mais elevadas, características associadas a tremores Parkinsonianos. Essas análises detalhadas são fundamentais para identificar a distribuição espectral das componentes de movimento e o ruído presentes no sinal coletado.

Figura 21 – Sinal bruto adquirido durante o experimento.



Fonte: Autoria própria.

Figura 22 – Espectro de frequência do sinal bruto (FFT).



Fonte: Autoria própria.

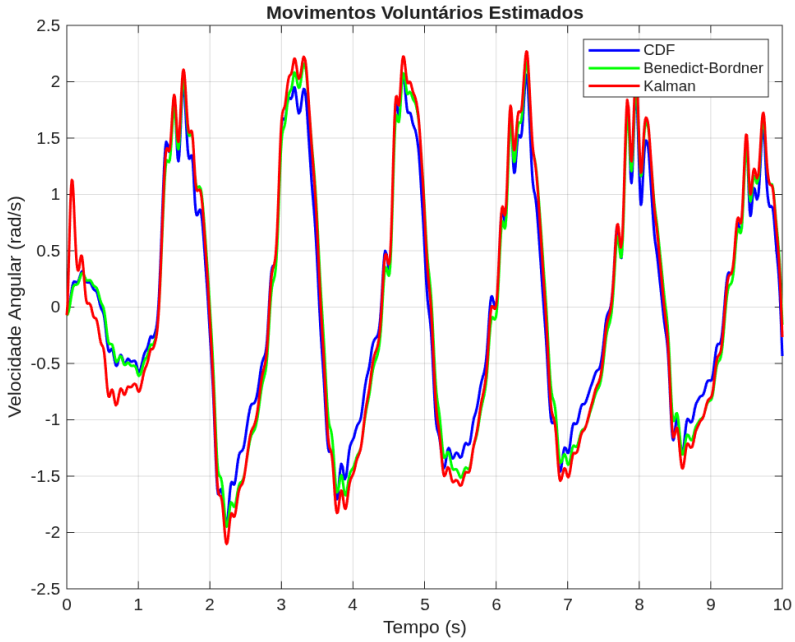
4.2 Algoritmos de Estimação do Movimento Voluntário:

Na primeira etapa de processamento, o movimento voluntário é estimado por meio de três técnicas de filtragem: o filtro Criticamente Amortecido (CDF), o filtro de Benedict-Bordner e o filtro de Kalman. A eficiência desses algoritmos no rastreamento da intenção de movimento é avaliada quantitativamente pela métrica Kinetic Tracking Error (KTE). A Figura 23 apresenta o comportamento temporal das saídas obtidas; observa-se que, embora as técnicas apresentem trajetórias convergentes, o filtro de Kalman parece demonstrar maior sensibilidade às variações abruptas do sinal, enquanto o CDF e o Benedict-Bordner exibem uma resposta ligeiramente mais atenuada.

Ademais, a Figura 24 apresenta a comparação das transformadas de Fourier dos sinais estimados em relação ao sinal bruto, evidenciando a capacidade de cada filtro em suprimir componentes de frequências mais elevadas (acima de 3 Hz) associadas ao tremor.

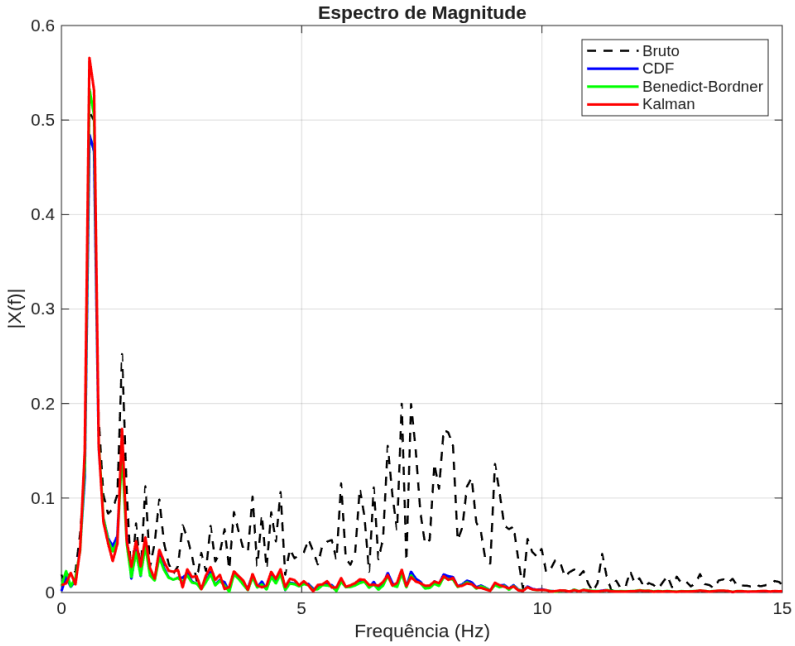
Por fim, a Figura 25 apresenta a comparação direta entre o sinal bruto e as estimativas geradas pelos filtros. Observa-se que, apesar da elevada oscilação e amplitude das componentes de tremor presentes no sinal original, os algoritmos foram capazes de isolar a envoltória correspondente ao movimento voluntário , reduzindo o ruído sem comprometer a fase do sinal de interesse mesmo com uma pequena defasagem.

Figura 23 – Compartivo entre a saída de cada filtro



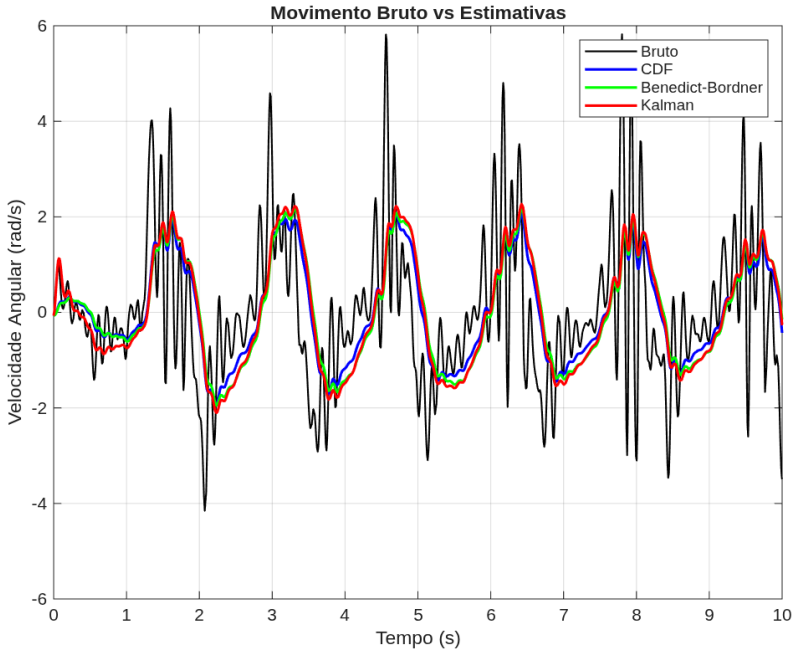
Fonte: Autoria própria.

Figura 24 – Comparação espectral entre sinal bruto e sinais filtrados.



Fonte: Autoria própria.

Figura 25 – Comparação entre sinal bruto e sinal estimado.



Fonte: Autoria própria.

4.3 Métrica de desempenho (KTE) dos Algoritmos de estimação do movimento voluntário

A Tabela 1 apresenta os resultados da métrica *Kinetic Tracking Error* (KTE) em rad/s para os filtros de movimento voluntário, permitindo uma comparação quantitativa do desempenho de cada método.

Tabela 1 – Resultados da métrica KTE para os filtros de movimento voluntário.

Filtro	**Valor KTE**
Criticamente Amortecido (CDF)	0,7355
Benedict-Bordner	0,8982
Kalman	0,8710

Fonte: Elaborado pelo autor (2026).

A partir das análises comparativas realizadas tanto no domínio do tempo quanto da frequência, conclui-se que o filtro Criticamente Amortecido (CDF) apresentou o desempenho mais consistente para a aplicação proposta. Embora as três técnicas tenham demonstrado eficácia na supressão das componentes de alta frequência do tremor, o CDF destacou-se por apresentar o menor erro residual de rastreamento (KTE), equilibrando de forma superior a atenuação de ruído e a preservação da integridade do movimento voluntário. Essa precisão, somada à sua eficiência

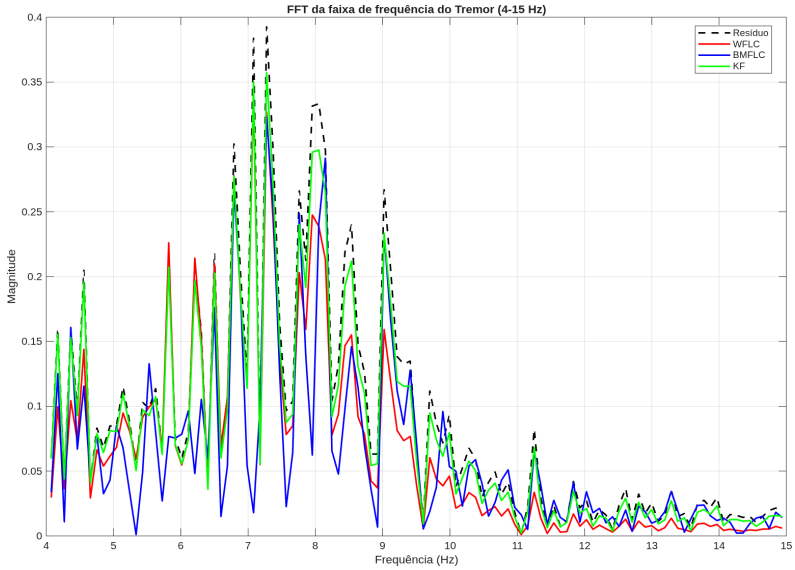
computacional, o torna a solução mais adequada para a estimação de intenção em tempo real no contexto de tecnologias assistivas.

4.4 Algoritmos de Estimação do Tremor de Parkinson:

Nesta fase, as técnicas adaptativas *Weighted-Frequency Fourier Linear Combiner* (WFLC), *Bandlimited Multiple Fourier Linear Combiner* (BMFLC) e o WFLC em cascata com o filtro de Kalman são avaliados por meio da métrica *Frequency Mean Square Error* (FMSEd) para a estimação do tremor Parkinsoniano.

Após a etapa de pré-processamento com o filtro CDF, cada uma das técnicas adaptativas é aplicada ao sinal residual para isolar a componente patológica. A Figura 26 apresenta a análise espectral, obtida via FFT, do sinal de tremor estimado, destacando a banda de interesse entre 4 e 15 Hz. Este intervalo é fundamental para a análise, pois compreende as frequências características do tremor em pacientes com Doença de Parkinson.

Figura 26 – Comparação da FFT do sinal bruto e dos sinais filtrados.

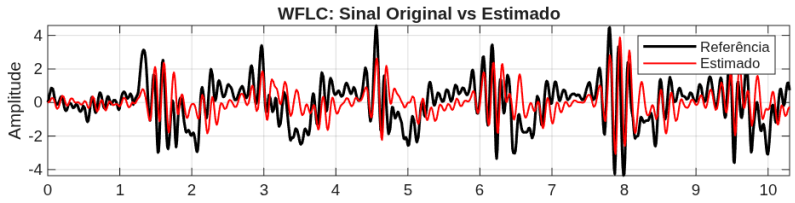


Fonte: Autoria própria.

- *WFLC*: A Figura 27 apresenta o rastreamento temporal do tremor realizado pelo algoritmo *Weighted-Frequency Fourier Linear Combiner* (WFLC). Observa-se que a técnica demonstra uma elevada capacidade de sincronismo de fase, acompanhando a frequência fundamental das oscilações do sinal de referência. Contudo, nota-se uma subestimação da amplitude em pontos de variações abruptas e surtos de tremor como nos instantes 4,5 s e 8 s, onde o sinal estimado não atinge os picos máximos do sinal real. Esse comportamento sugere que, embora o WFLC seja robusto na identificação da frequência, a sua dinâmica

de ajuste de ganho de amplitude pode apresentar uma limitação frente a transientes de alta energia, resultando em um erro residual nessas regiões.

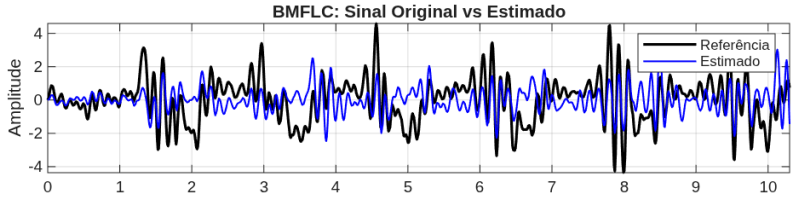
Figura 27 – Comparação entre sinal bruto e sinal estimado por WFLC.



Fonte: Autoria própria.

- *BMFLC*: A Figura 28 ilustra o desempenho do algoritmo *Bandlimited Multiple Fourier Linear Combiner* (BMFLC) na estimativa do tremor. Observa-se que a técnica apresentou limitações no rastreamento do sinal de referência . Nota-se uma incapacidade em acompanhar as variações de amplitude do tremor. Enquanto o sinal de referência exibe surtos de energia com amplitudes elevadas, a saída do BMFLC permanece significativamente atenuada. Este comportamento sugere que os parâmetros do banco de filtros ou os ganhos de adaptação não foram capazes de capturar a dinâmica transitória do sinal, resultando em uma subestimação severa da intenção patológica.

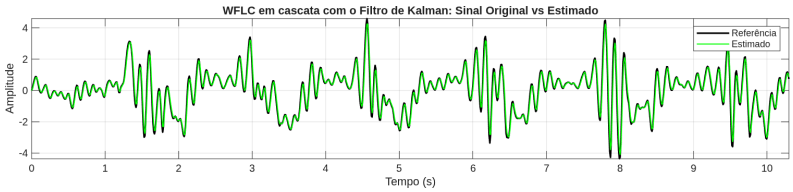
Figura 28 – Comparação entre sinal bruto e sinal estimado por BMFLC.



Fonte: Autoria própria.

- *WFLC e Filtro de Kalman em cascata*: Os resultados referentes à aplicação do WFLC em cascata com o filtro de Kalman estão apresentados na Figura 29. A imagem exibe o sinal original e a respectiva estimativa de estado realizada pelo algoritmo. Diferente das técnicas adaptativas anteriores, o filtro de Kalman demonstrou um desempenho superior de rastreamento, conseguindo acompanhar as variações abruptas de amplitude e manter o sincronismo de fase com erro residual mínimo. A capacidade do filtro em lidar com as incertezas do sinal e prever o estado seguinte resultou em uma reconstrução altamente fidedigna do tremor, sendo capaz de capturar os surtos de energia sem apresentar o atraso ou a atenuação observados nos algoritmos WFLC e BMFLC.

Figura 29 – Comparação entre sinal bruto e sinal estimado por WFLC em cascata com o Filtro de Kalman.



Fonte: Autoria própria.

4.5 Métrica de desempenho (FMSEd) dos algoritmos de estimação do tremor Parkinsoniano

A Tabela 2 apresenta os resultados da métrica *Frequency-domain Mean Square Error* (FMSEd) em rad/s para as técnicas adaptativas avaliadas, permitindo uma comparação quantitativa do desempenho de cada método no rastreamento do tremor.

Tabela 2 – Resultados da métrica FMSEd para os algoritmos de estimação do tremor de Parkinson

Técnica Adaptativa	**Valor FMSEd (rad/s)**
WFLC	1,163830
BMFLC	1,285345
Filtro de Kalman (KF)	0,257134

Fonte: Elaborado pela autora (2026).

Com base nos resultados apresentados, observa-se que a abordagem utilizando o algoritmo WFLC em cascata com o filtro de Kalman obteve o desempenho superior, apresentando o menor erro médio de estimação. Este arranjo permitiu uma redução significativa do erro em comparação ao uso isolado do BMFLC ou do WFLC, que demonstraram limitações em acompanhar a dinâmica de amplitude e fase do sinal, respectivamente.

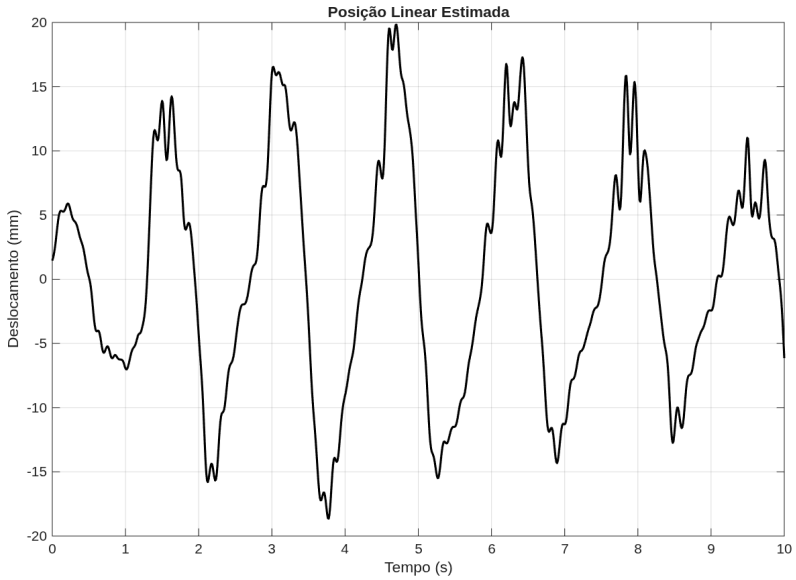
Portanto, para o desenvolvimento deste estudo, a estrutura de processamento definida consiste na aplicação do filtro CDF para o rastreio do movimento voluntário, seguida pela combinação do WFLC com o filtro de Kalman para a estimação precisa do tremor. Essa conFiguração será a base para a reprodução dos sinais no experimento em bancada.

4.6 Deslocamento Linear Estimado:

A Figura 30 ilustra a evolução temporal da posição linear, obtida por meio da fusão sensorial dos dados provenientes do acelerômetro e do giroscópio de um eixo. Este sinal proces-

sado representa a trajetória de referência (*setpoint*) que o protótipo deverá rastrear durante os experimentos em bancada, servindo como parâmetro para a avaliação do sistema de controle.

Figura 30 – Deslocamento Linear Estimado.



Fonte: Autoria própria.

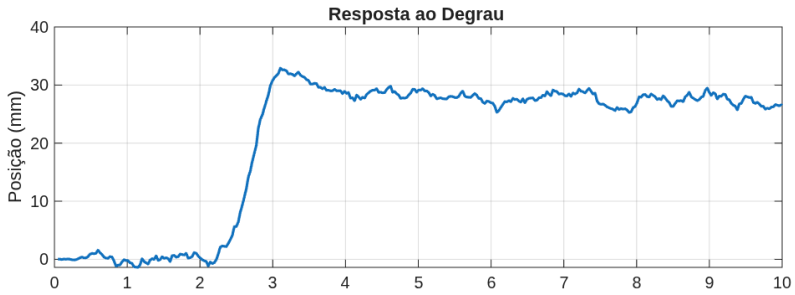
4.7 Resposta da Planta ao Degrau

A Figura 31 apresenta o comportamento dinâmico inicial da planta obtido a partir de um ensaio experimental submetido à excitação por degrau. Complementarmente, a Figura 32 ilustra o sinal de controle aplicado ao sistema, no qual verifica-se que, no instante $t = 2\,\text{s}$, foi introduzido um degrau de amplitude correspondente a 50%, ocasionando a variação do sinal de controle de 0% para 50%.

A resposta experimental da planta, mostrada na Figura 32, evidencia inicialmente a presença de um atraso de transporte imediatamente após a aplicação do degrau. Na sequência, observa-se uma rápida elevação da posição do sistema, atingindo um valor máximo aproximado de 33 mm no instante $t = 3\,\text{s}$, caracterizando a ocorrência de sobressinal. Posteriormente, a resposta converge para a região de regime permanente, apresentando oscilações de pequena amplitude em torno da faixa compreendida entre 27 mm e 30 mm.

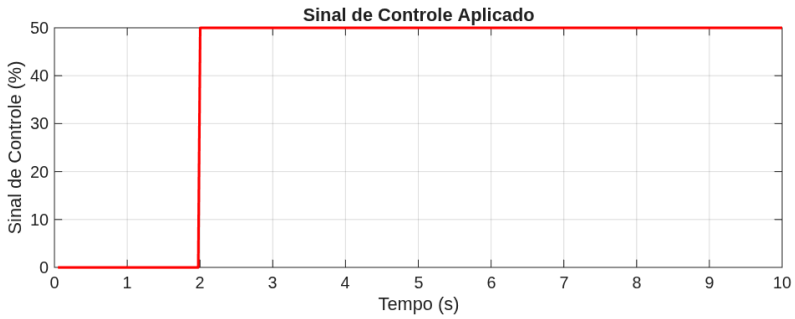
Os dados experimentais obtidos nesta etapa foram armazenados para posterior utilização no processo de identificação de sistemas (*System Identification*). A partir dos sinais de entrada e saída adquiridos durante o ensaio, será possível estimar o modelo da planta, permitindo a análise do comportamento do sistema e o desenvolvimento de estratégias de controle mais adequadas.

Figura 31 – Resposta ao degrau unitário.



Fonte: Autoria própria.

Figura 32 – Sinal de entrada para excitação visando à identificação.



Fonte: Autoria própria.

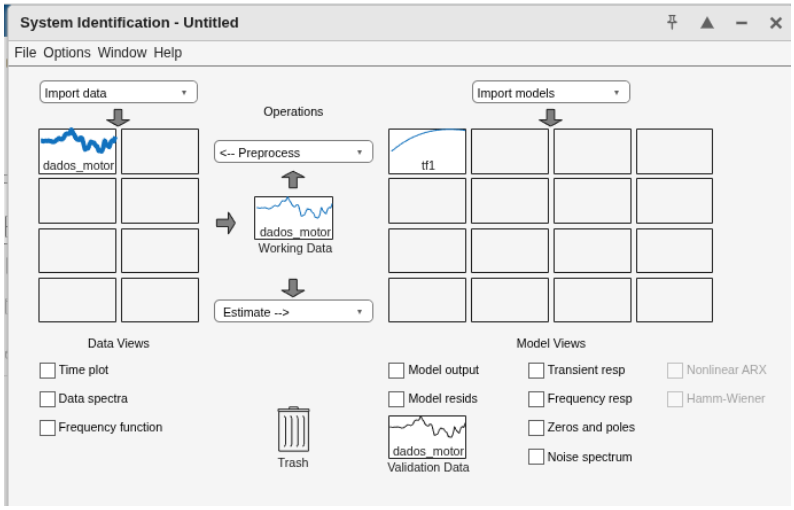
4.8 Identificação do modelo da planta:

Os dados experimentais obtidos durante o ensaio em degrau foram utilizados na ferramenta *System Identification Toolbox* do *MATLAB*, conforme ilustrado na Figura 33. A partir dos sinais de entrada (*Controle PWM*) e saída (*Posição do Sensor*) da planta, realizou-se o processo de identificação de dois modelos discretos. O objetivo foi representar matematicamente a dinâmica do sistema por meio de funções de transferência, adotando um período de amostragem de $T_s = 0{,}02\,\text{s}$ para ambos os casos.

O primeiro modelo, de segunda ordem, apresentou um índice de compatibilidade (*best fit*) de 86,3%, indicando uma boa concordância entre a resposta estimada e os dados experimentais coletados, conforme apresentado na Figura 34. Adicionalmente, o modelo obteve um Erro de Predição Final (Final Prediction Error) de 2,8105. Esta métrica estatística avalia a qualidade preditiva do sistema ponderando o erro residual em relação à complexidade estrutural adotada, atuando como um critério que penaliza o excesso de parâmetros (polos e zeros) para evitar o superajuste (overfitting). A função de transferência discreta identificada para este caso é dada por:

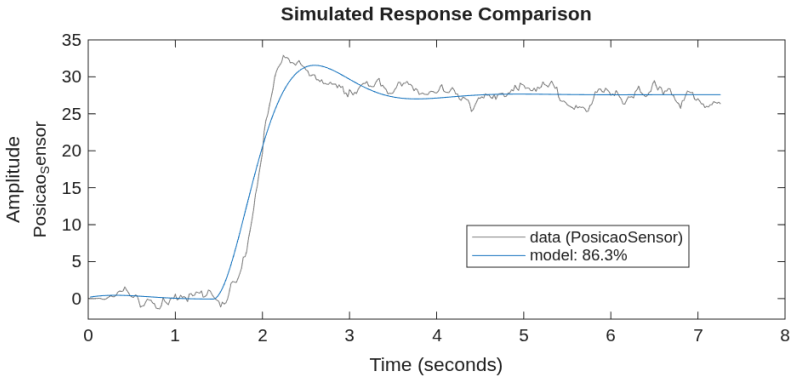
$$G_2(z) = \frac{0{,}002127\,z^{-1}}{1 - 1{,}932\,z^{-1} + 0{,}9358\,z^{-2}} \tag{4.1}$$

Figura 33 – Toolbox System Identification.



Fonte: Autoria própria.

Figura 34 – Modelo de 2ª Ordem Aproximado da Planta.

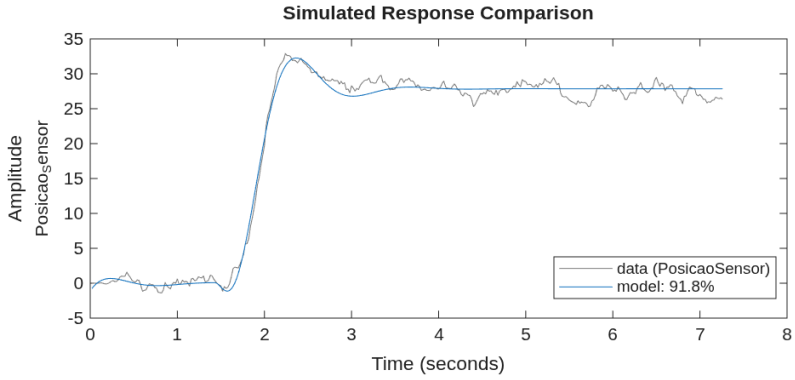


Fonte: Autoria própria.

Buscando uma representação ainda mais fiel à dinâmica real da planta, identificou-se um segundo modelo, de terceira ordem, que obteve um índice de compatibilidade superior, alcançando 91,83%, como ilustrado na Figura 35. Além do melhor ajuste aos dados, este modelo apresentou um Erro de Predição Final (FPE) de 1,01566. Essa redução expressiva do FPE em comparação ao modelo anterior demonstra que o aumento da complexidade estrutural foi matematicamente justificado, proporcionando um ganho real na capacidade preditiva sem incorrer em superajuste (*overfitting*). A função de transferência discreta identificada para este modelo é descrita por:

$$G_3(z) = \frac{-0{,}002893\,z^{-1} + 0{,}003547\,z^{-2}}{1 - 2{,}794\,z^{-1} + 2{,}609\,z^{-2} - 0{,}8137\,z^{-3}} \tag{4.2}$$

Figura 35 – Modelo de 3ª Ordem Aproximado da Planta.



Fonte: Autoria própria.

4.9 Sintonia PID-IMC:

Com a função de transferência discreta devidamente identificada dos modelos, utilizou-se a aproximação de Tustin para converter o sistema para o domínio contínuo. Desconsiderando termos de alta ordem para isolar a dinâmica principal, obteve-se a seguinte função de transferência limpa:

$$G(s) = \frac{5,499}{s^2 + 3,32s + 9,825} \tag{4.3}$$

A partir dessa modelagem, foi possível extrair os parâmetros reais do processo contínuo:

- **Ganho estático (K_s):** 0,5597
- **Fator de amortecimento (ζ):** 0,529
- **Frequência natural (ω_n):** 3,1344 rad/s
- **Atraso de transporte (θ):** 0 s

Com os parâmetros do processo definidos, adotou-se o método de sintonia IMC (*Internal Model Control*). Sintonizou-se o sistema para ter uma constante de tempo de malha fechada desejada por meio de testes para descobrir a melhor sintonia com o menor tempo, o valor encontrado foi de $\tau_{mf} = 4$ s . Aplicando as formulações do IMC, os parâmetros obtidos para o controlador PID contínuo foram apresentados na Tabela 3.

Tabela 3 – Parâmetros do controlador PID obtidos pelo método IMC

Parâmetro	**Valor**
Proporcional (k_p)	0,1508
Integral (k_i)	0,4467
Derivativo (k_d)	0,0455

Isso resultou na seguinte função de transferência para o controlador contínuo $C(s)$:

$$C(s) = \frac{0,04546s^2 + 0,1508s + 0,4467}{s} \tag{4.4}$$

Em seguida, o controlador contínuo foi discretizado utilizando o método de Tustin, considerando um tempo de amostragem de $T_s = 0,02$ s, para implementação prática no sistema digital. O controlador discreto obtido foi:

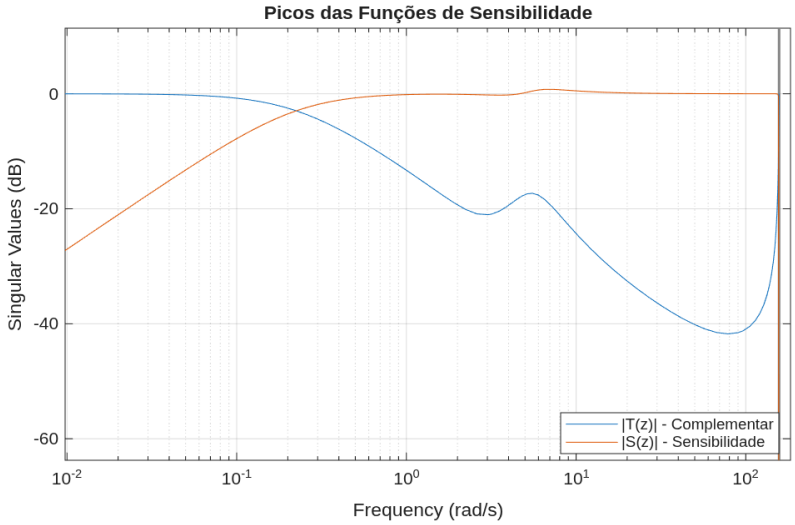
$$C(z) = \frac{4,702z^2 - 9,084z + 4,4}{z^2 - 1} \tag{4.5}$$

4.10 Análise de Estabilidade e Robustez

Com o controlador digital $C(z)$ e a planta discreta $G_3(z)$ definidos, avaliou-se a robustez do sistema em malha fechada $T(z)$ por meio da norma H_∞ das funções de sensibilidade. O pico máximo da função de sensibilidade complementar foi $M_t = \mathbf{1,00}$, enquanto o pico da função de sensibilidade foi $M_s = \mathbf{1,0938}$. Esses valores estão abaixo dos limites de referência da literatura ($M_t < 1,5$ e $M_s < 2,0$), indicando baixa amplificação de ruído e boa rejeição a distúrbios, o que caracteriza uma excelente margem de robustez. O gráfico correspondente é apresentado na Figura 36.

Adicionalmente, a Margem de Ganho Estimada foi de $\mathbf{6,02}$ **dB**, enquanto a Margem de Fase Estimada foi de $\mathbf{54,46}^\circ$. Esses resultados indicam que o sistema apresenta boa estabilidade e adequada tolerância a variações paramétricas e atrasos dinâmicos. Em conjunto, as métricas de sensibilidade e as margens de estabilidade confirmam que o controlador projetado garante desempenho robusto, com boa rejeição a perturbações e estabilidade em malha fechada.

Figura 36 – Valores Singulares: Picos das Funções de Sensibilidade T (z) e S(z).



Fonte: Autoria própria.

4.11 Análise dos Resultados Experimentais em Bancada

Os ensaios experimentais realizados em bancada, operando sob a ação do controlador PID projetado, permitiram avaliar o comportamento dinâmico do sistema por meio das curvas de rastreamento de trajetória e do respectivo esforço de controle. A Figura 37 apresenta a validação do desempenho da malha, detalhando a comparação entre a leitura bruta do sensor, a posição filtrada do sistema e a referência ideal de posição linear ao longo de um período de 30 segundos.

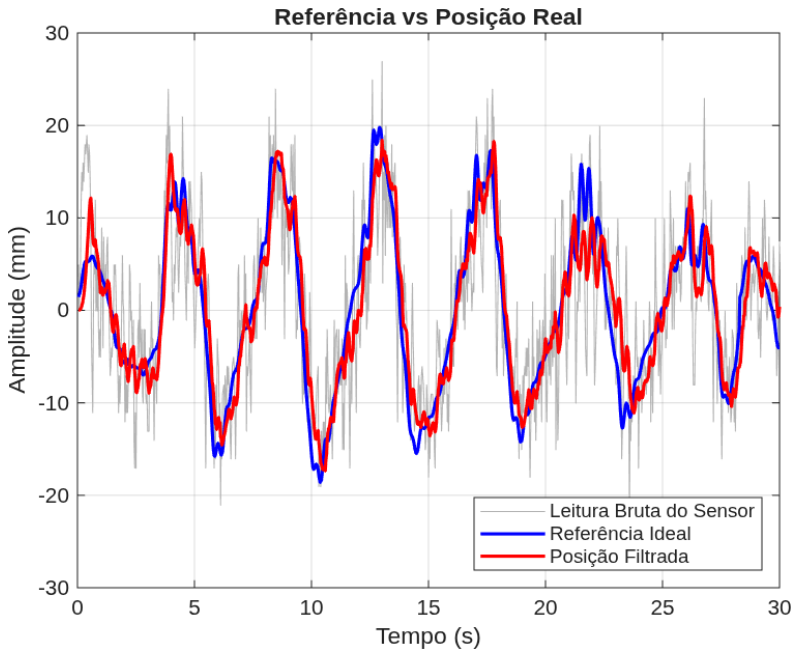
Conforme observado na Figura 37, a variável controlada acompanha a trajetória de referência, evidenciando a eficácia da estratégia de controle implementada. Um aspecto de destaque no ensaio é a presença substancial de ruído na medição da planta (leitura bruta do sensor, em cinza). No entanto, a posição filtrada (em vermelho) demonstra a eficácia do filtro de Kalman que consegue suavizar a resposta e seguir a referência ideal (em azul) de forma satisfatória. Os desvios de fase e os erros de amplitude são mínimos, mesmo diante das reversões contínuas e das dinâmicas complexas exigidas pela trajetória de referência.

A Figura 38 ilustra a ação de controle (saída do controlador PID) gerada para garantir o rastreamento da referência durante o ensaio. O sinal atua de forma altamente dinâmica e ágil para compensar tanto as variações abruptas da trajetória quanto as perturbações decorrentes do ruído de medição remanescente. A eficácia dessa compensação está intrinsecamente ligada ao ajuste das constantes do controlador (K_p, K_i e K_d) e às restrições físicas impostas pelo atuador.

Além da sintonia matemática, a robustez do rastreamento dependeu da adaptação do sinal de controle à realidade do *hardware*. O esforço de controle calculado foi mapeado para pulsos PWM restritos à janela operacional do atuador). O limite inferior reflete a tensão mínima absoluta de partida do motor; valores inferiores não geram torque suficiente para romper a inércia

do rotor, resultando apenas em dissipação térmica.

Figura 37 – Comparação entre a posição linear estimada, leitura bruta do sensor e a posição filtrada do sistema.

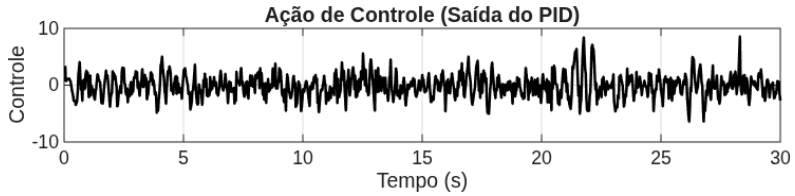


Fonte: Autoria própria.

A análise temporal do erro, apresentada na Figura 39, confirma a eficácia do sistema de controle em malha fechada. Mesmo diante de um sinal de referência com dinâmica complexa e comportamento oscilatório, com amplitudes variando significativamente entre $-20\,\text{mm}$ e $+20\,\text{mm}$, observa-se que o erro instantâneo de rastreamento (curva verde) permaneceu predominantemente restrito a uma faixa aproximada de $\pm 5\,\text{mm}$.

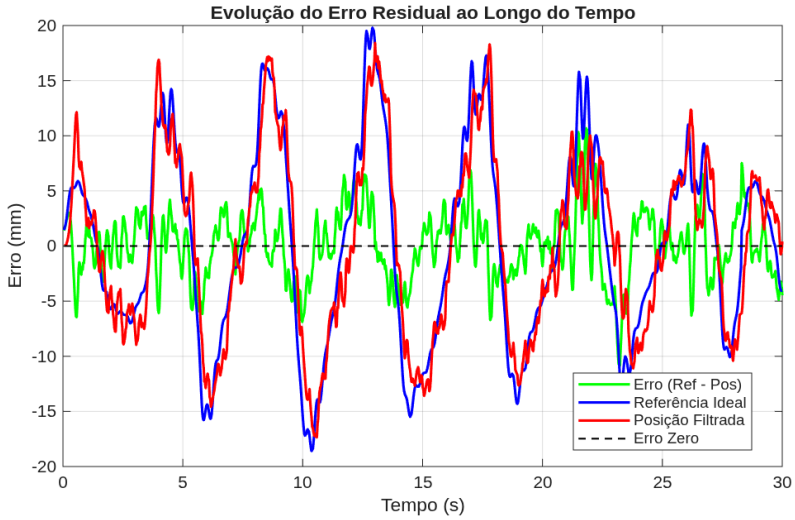
Nota-se que os picos transitórios de erro estão associados aos instantes de inversão de sentido e às regiões de maior variação da trajetória de referência, sendo mais evidentes no intervalo de 20 a 25 segundos. Esse comportamento é esperado em sistemas mecânicos reais e está relacionado ao atraso de fase intrínseco da planta. Tal atraso decorre, simultaneamente, da inércia física do sistema, que impõe resistência a variações abruptas de aceleração, e dos atrasos introduzidos pelo processamento digital e pela dinâmica de filtragem aplicada às medições do sensor. Contudo, mesmo na presença desses efeitos dinâmicos, o sistema apresenta desempenho satisfatório, mantendo o rastreamento adequado da referência ao longo de toda a trajetória.

Figura 38 – Sinal de controle gerado pelo controlador PID durante o ensaio.



Fonte: Autoria própria.

Figura 39 – Evolução do erro residual instantâneo confrontado com a dinâmica do sistema.



Fonte: Autoria própria.

5 CONCLUSÃO

Este trabalho teve como objetivo investigar, caracterizar e reproduzir mecanicamente o tremor patológico associado à Doença de Parkinson (DP), estabelecendo uma sólida base tecnológica e metodológica para futuras aplicações em controle ativo e no desenvolvimento de tecnologias assistivas. A separação entre o movimento voluntário e a componente patológica a partir de sinais inerciais obtidos por uma Unidade de Medição Inercial (IMU) mostrou-se altamente viável.

Nos testes de estimação, o filtro Criticamente Amortecido (CDF) destacou-se no rastreamento do movimento voluntário ($KTE = 0{,}7355$), enquanto a abordagem em cascata utilizando o algoritmo WFLC e o filtro de Kalman obteve precisão superior na reconstrução do tremor ($FMSE_d = 0{,}2571$ rad/s). O sistema de controle sintonizado via PID-IMC exibiu elevada robustez e estabilidade em malha fechada, com margens de ganho (6,02 dB) e de fase (54,46°) adequadas, garantindo a rejeição de perturbações e tolerância a incertezas dinâmicas mesmo quando validado em um modelo de ordem superior com $91,8\%$ de compatibilidade com a dinâmica real da bancada. Na validação experimental, a plataforma biela-manivela provou a reprodutibilidade do tremor em tempo real, mantendo o erro de rastreamento na faixa de ± 5 mm, consolidando-se como uma ferramenta experimental robusta e segura.

Como propostas de continuidade e trabalhos futuros, projeta-se a transição da abordagem unidimensional (1D) para um sistema expandido em três eixos ortogonais (3D), visando aproximar a pesquisa da realidade clínica multivariada do tremor biomecânico, que engloba movimentos combinados de flexão-extensão, desvio ulnar-radial e pronação-supinação do punho. No âmbito do hardware, essa evolução demanda a substituição da bancada atual por uma estrutura robótica ou mecanismo paralelo de três graus de liberdade (3 DoF), como uma articulação esférica motorizada ou um sistema do tipo gimbal, acionada por micro-atuadores ortogonais rápidos e instrumentada com IMUs triaxiais para captação simultânea nos eixos X, Y e Z.

Em relação aos algoritmos de estimação, propõe-se a formulação vetorial triaxial do Weighted-Frequency Fourier Linear Combiner (WFLC) integrada a variantes não lineares do filtro de Kalman, como o Filtro de Kalman Estendido (EKF) ou Unscented (UKF), para mitigar os acoplamentos e as não linearidades das rotações espaciais. Para as malhas de controle, a transição para estratégias multivariáveis (MIMO), tais como o Controle Preditivo Baseado em Modelo (MPC) e o Controle Robusto (H_∞), viabilizará a rejeição de perturbações cruzadas entre os eixos e garantirá estabilidade perante as variações dinâmicas musculoesqueléticas. Alguns códigos utilizados no desenvolvimento deste projeto estarão disponíveis em <[https://github.com/monique-santos/ParkinsonTremorEstimation](https://www.google.com/search?q=https://github.com/monique-santos/ParkinsonTremorEstimation)>.

REFERÊNCIAS

ABUSRAIR, A. H.; ELSEKAILY, W.; BOHLEGA, S. Tremor in parkinson's disease: From pathophysiology to advanced therapies. **Tremor and Other Hyperkinetic Movements**, v. 12, n. 29, 2022.

BAR-SHALOM, Y.; LI, X. R. **Estimation and Tracking: Principles, Techniques and Software**. Norwood, MA, USA: Artech House, 1998.

BAR-SHALOM, Y.; LI, X. R.; KIRUBARAJAN, T. **Estimation with applications to tracking and navigation**. New York: John Wiley & Sons, 2001.

BENEDICT, T. R.; BORDNER, G. Synthesis of an optimal set of radar track-while-scan smoothing equations. **IRE Transactions on Automatic Control**, IEEE, v. 7, n. 4, p. 27–32, 1962.

BRAZIS, P. W.; MASDEU, J. C.; BILLER, J. **Localization in Clinical Neurology**. 7. ed. [S.l.]: Wolters Kluwer, 2016.

BROOKNER, E. **Tracking and Kalman Filtering Made Easy**. Hoboken, NJ, USA: John Wiley & Sons, 1998.

BUKI, E. et al. Vib-bracelet: a passive absorber for attenuating forearm tremor. **Medical Biological Engineering Computing**, v. 56, p. 923–930, 2018. Disponível em: <https://doi.org/10.1007/s11517-017-1742-7>.

BUTLER, R. D. et al. Differentiating postural and kinetic tremor responses to deep brain stimulation in essential tremor. **Movement Disorders Clinical Practice**, v. 12, n. 2, p. 166–176, 2025. Disponível em: <https://movementdisorders.onlinelibrary.wiley.com/doi/abs/10.1002/mdc3.14256>.

CAMPBELL, W. W. **DeJong's The Neurologic Examination**. 6. ed. [S.l.]: Lippincott Williams & Wilkins, 2005.

CASTONGUAY, A.-M.; GRAVEL, C.; LEVESQUE, M. Treating parkinson's disease with antibodies: Previous studies and future directions. **Journal of Parkinson's Disease**, v. 11, p. 71–92, 2021.

DELATORRE, A. **IMU-Based Measurement and Classification System of Tremors in Parkinson's Disease**. Dissertação (Master's thesis) — Universidade Federal de Santa Catarina, Florianópolis, Brazil, 2020. Disponível em: <https://repositorio.ufsc.br/handle/123456789/219349>.

EGER, J. S.; PORATH, M. C.; DONATELLI, G. D. **A good-practices guideline for 6-DoF IMU-based dead-reckoning**. Joinville, Brazil, 2025. Disponível em: <https://lcv.fee.unicamp.br/wp-content/images/BTSym-22-Brasil/papers/paper_057.pdf>.

ETTER, D.; STEARNS, S. Adaptive estimation of time delays in sampled data systems. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 29, n. 3, p. 582–587, 1981.

GALLEGO, J. A. et al. Real-time estimation of pathological tremor parameters from gyroscope data. **Sensors**, MDPI, v. 10, n. 3, p. 2129–2149, 2010.

GOETZ, C. G. The history of parkinson's disease: early clinical descriptions and neurological therapies. **Cold Spring Harbor perspectives in medicine**, v. 1, n. 1, 2011.

GOLDSTEIN, H.; POOLE, C. P.; SAFKO, J. L. **Classical Mechanics: Pearson New International**. 3. ed. London: Pearson, 2014. 664 p.

GONZALEZ, J. et al. Optimal digital filtering for tremor suppression. **IEEE Transactions on Biomedical Engineering**, v. 47, n. 5, p. 664–673, 2000.

HAYES, M. T. Parkinson's disease and parkinsonism. **The American Journal of Medicine**, v. 132, n. 7, p. 802–807, 2019.

KALIA, L. V.; LANG, A. E. Parkinson's disease. **The Lancet**, v. 386, n. 9996, p. 896–912, 2015. ISSN 0140-6736. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0140673614613933>.

KOZLOVSZKY, M. et al. Imu based human movement tracking. In: **2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)**. [S.l.: s.n.], 2018. p. 0240–0244.

LAINE, C. M.; VALERO-CUEVAS, F. J. Parkinson's disease exhibits amplified intermuscular coherence during dynamic voluntary action. **Frontiers in Neurology**, v. 11, n. 204, 2020.

LATIF, S. et al. Dopamine in parkinson's disease. **Clinica Chimica Acta**, v. 522, p. 114–126, 2021. ISSN 0009-8981. Disponível em: <https://www.sciencedirect.com/science/article/pii/S000989812100276X>.

LENKA, A.; JANKOVIC, J. Tremor syndromes: An updated review. **Frontiers in Neurology**, v. 12, 2021.

LIN, P. et al. A digital assessment system for evaluating kinetic tremor in essential tremor and parkinson's disease. **BMC Neurology**, v. 18, p. 25, 2018. Disponível em: <https://doi.org/10.1186/s12883-018-1027-2>.

LONG, E.; REUTHER, W. General overview of parkinson's disease. **Advances in Parkinson's Disease**, v. 14, n. 4, p. 47–71, 2025.

MACHADO, B. da S. **Estudo Comparativo entre Filtro Complementar e Filtro de Kalman Estendido em uma Aplicação de Estimação de Atitude**. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 2023. Acesso em: 14 maio 2026. Disponível em: <https://repositorio.ufsc.br/handle/123456789/254228>.

MALAK, A. L. S. B. et al. Symptoms of depression in patients with mild cognitive impairment in parkinson's disease. **Dementia & Neuropsychologia**, v. 11, n. 2, p. 145–153, 2017.

MARSILI, L. et al. Device-aided therapies for advanced parkinson disease: insights from an international survey. **Neurological Sciences**, v. 42, n. 7, p. 2961–2964, 2021.

MENDONCA, M. D. et al. Relative sparing of dopaminergic terminals in the caudate nucleus is a feature of rest tremor in parkinson's disease. **npj Parkinson's Disease**, v. 10, n. 209, 2024.

MIRA, A. et al. Assistive technology for parkinson's disease: A systematic review. **Sensors**, v. 22, n. 13, p. 5051, 2022.

MORARI, M.; ZAFIRIOU, E. **Robust Process Control**. Englewood Cliffs, N.J.: Prentice-Hall, 1989.

MUNHOZ, R. P. et al. The clinical diagnosis of parkinson's disease. **Arquivos de Neuro-Psiquiatria**, v. 82, p. s00431777775, 2024. Disponível em: <https://doi.org/10.1055/s-0043-1777775>.

OPPENHEIM, A. V.; SCHAFER, R. W. **Discrete-Time Signal Processing**. 3. ed. Upper Saddle River, NJ: Pearson, 2010.

PENA-ZELAYETA, L. et al. Redefining non-motor symptoms in parkinson's disease. **Journal of Personalized Medicine**, v. 15, n. 5, p. 172, Apr 2025. Disponível em: <https://doi.org/10.3390/jpm15050172>.

RIVIERE, C. N.; RADER, R. S.; THAKOR, N. V. Adaptive canceling of physiological tremor for improved precision in microsurgery. **IEEE Transactions on Biomedical Engineering**, v. 45, n. 7, p. 839–846, July 1998. ISSN 0018-9294.

RIVIERE, C. N.; THAKOR, N. V. Modeling and canceling tremor in human-machine interfaces. **IEEE Engineering in Medicine and Biology Magazine**, IEEE, v. 15, n. 3, p. 29–36, 1996.

ROCON, E. **Reducción Activa de Temblor Patológico de Miembro Superior Mediante Exoesqueletos Robóticos**. Tese (Doutorado) — Universidad Politécnica de Madrid, Madrid, Spain, 2006.

SÁNCHEZ-FERRO, Á. et al. New methods for the assessment of parkinson's disease (2005 to 2015): A systematic review. **Movement Disorders**, v. 31, n. 9, p. 1283–1292, 2016.

SCHLICKMANN, T. H. et al. Prevalence, distribution and future projections of parkinson disease in brazil: Insights from the elsi-brazil cohort study. **The Lancet Regional Health – Americas**, p. 101046, 2025.

SEBORG, D. E. et al. **Process Dynamics and Control**. 4. ed. Hoboken, NJ: John Wiley & Sons, 2017.

SHA, R. et al. Innovations in parkinson's disease: Strategies and novel technologies. **Cureus**, v. 17, n. 7, 2025.

SILVEIRA, A. et al. A case study on the attitude control of the vls-1 launcher in the vibratory regime*. In: **2025 16th IEEE International Conference on Industry Applications (INDUSCON)**. [S.l.: s.n.], 2025. p. 788–795.

SIMON, D. **Optimal State Estimation**. [S.l.]: Wiley, 2006.

SKOGESTAD, S.; POSTLETHWAITE, I. **Multivariable Feedback Control: Analysis and Design**. 2. ed. Chichester: John Wiley & Sons, 2005.

STEVENS, B. L.; LEWIS, F. L.; JOHNSON, E. N. **Aircraft Control and Simulation: Dynamics, Controls Design, and Autonomous Systems**. 3. ed. [S.l.]: John Wiley & Sons, Inc., 2016.

STMicroelectronics. **VL53L0X: World's smallest Time-of-Flight (ToF) ranging sensor**. Genebra, 2016. Datasheet técnico. Disponível em: <https://www.st.com/resource/en/datasheet/vl53l0x.pdf>. Acesso em: 21 mai. 2026.

SU, D. et al. Projections for prevalence of parkinson's disease and its driving factors in 195 countries and territories to 2050: modelling study of global burden of disease study 2021. **BMJ**, BMJ Publishing Group Ltd, v. 388, 2025. Disponível em: <https://www.bmj.com/content/388/bmj-2024-080952>.

TAZARTES, D. An historical perspective on inertial navigation systems. In: **2014 International Symposium on Inertial Sensors and Systems (INERTIAL)**. [S.l.: s.n.], 2014. p. 1–5.

TITTERTON, D. H.; WESTON, J. L. **Strapdown Inertial Navigation Technology**. 2. ed.. ed. Stevenage: Institution of Electrical Engineers, 2004. v. 17.

VARGHESE, J. et al. **PADS - Parkinson's Disease Smartwatch Dataset (version 1.0.0)**. 2024. <https://physionet.org/content/parkinsons-disease-smartwatch/1.0.0/>. PhysioNet. DOI: 10.13026/m0w9-zx22.

VAZ, C. A.; KONG, X.; THAKOR, N. V. An adaptive estimation of periodic signals using a fourier linear combiner. **IEEE Transactions on Signal Processing**, v. 42, n. 1, p. 1–10, Jan 1994. ISSN 1053-587X.

VELUVOLU, K. C. et al. Bandlimited multiple Fourier linear combiner for real-time tremor compensation. In: IEEE. **Proceedings of the 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS)**. Kiel, Germany, 2007. p. 2847–2850.

VIJIARATNAM, N. et al. Progress towards therapies for disease modification in parkinson's disease. **The Lancet. Neurology**, v. 20, n. 7, p. 559–572, 2021. Disponível em: <https://doi.org/10.1016/S1474-4422(21)00061-2>.

WIDROW, B. et al. Adaptive noise canceling: Principles and applications. **Proceedings of the IEEE**, v. 63, n. 12, p. 1692–1716, 1975.

WOODMAN, O. J. **An Introduction to Inertial Navigation**. Cambridge, UK, 2007.

ZHOU, Y. et al. Development of a wearable tremor suppression glove. In: **2018 7th IEEE International Conference on Biomedical Robotics and Biomechatronics (Biorob)**. [S.l.: s.n.], 2018. p. 640–645.

ZUBAIR, M.; SUTHAR, B.; JUNG, S. Design and analysis of flexure mechanisms for human hand tremor compensation. **IEEE Access**, v. 10, p. 36006–36017, 2022.