

# Atenuação do Sinal de Tremores nas Mãos: uma Análise Comparativa de Algoritmos Adaptativos

Jéssica Cristina Tironi

jessica.tironi@edu.univali.br

Escola Politécnica, Universidade do Vale do Itajaí  
Itajaí, SC, Brazil

Anita M. da Rocha Fernandes

anita.fernandes@univali.br

Escola Politécnica, Universidade do Vale do Itajaí  
Itajaí, SC, Brazil

Wemerson Delcio Parreira\*

wemerson.delcio@puc-campinas.edu.br

Escola Politécnica, Pontifícia Universidade Católica de  
Campinas  
Campinas, SP, Brazil

Renata Coelho Borges

renatacoelho@utfpr.edu.br

Universidade Tecnológica Federal do Paraná  
Curitiba, PR, Brazil

## ABSTRACT

In this research, we provide a detailed analysis of five adaptive algorithms to attenuate hand tremors during writing. The evaluated algorithms included Filtered Least Mean Squared (Fx-LMS), Filtered Normalized LMS (Fx-NLMS), Hybrid Fx-LMS&NLMS, Recursive Least Squares (RLS), and Kalman Filter. We have conducted simulations to assess the performance of these algorithms using the NewHandPD dataset, which contains hand tremor signals from 31 patients. Our results show that the mean squared error (MSE) values of -38 dB for Fx-LMS, -42 dB for Fx-NLMS, -44 dB for Fx-LMS and NLMS, -53 dB for RLS, and -50 dB for the Kalman Filter. RLS had the lowest MSE and superior adaptation. On the other hand, the Kalman Filter demonstrated faster convergence to the steady state, which is six times faster than RLS.

## KEYWORDS

Adaptive Algorithms, hand tremor, MSE.

## 1 INTRODUÇÃO

O tremor é caracterizado por oscilações rítmicas e involuntárias de uma parte do corpo ou do corpo inteiro, com frequência e amplitude quase constantes. Clinicamente, os tremores são classificados em duas categorias principais: tremores de repouso e tremores de ação. O tremor de repouso ocorre quando o músculo se encontra relaxado, por exemplo, quando as mãos estão apoiadas em alguma superfície. Em atividade, os tremores de repouso são mínimos ou ausentes. O tremor de ação se manifesta durante o movimento voluntário do músculo, podendo ou não se intensificar ao atingir um alvo. Esse distúrbio pode estar associado a várias condições médicas, tais como tremor essencial (TE), tremor de repouso parkinsoniano (TP), distúrbios metabólicos, efeitos adversos de medicamentos, abuso de álcool, drogas e estresse emocional [1-3].

O TE é uma das formas mais comuns de tremor, sendo mais prevalente em idosos. Manifesta-se como um tremor postural bilateral, com frequência variando de 6 a 12 Hz. Os membros superiores são geralmente os mais afetados, mas, à medida que a doença progride, a cabeça e a voz também podem ser comprometidas. De outra forma, o TP é predominantemente um tremor de repouso, com frequência variando de 3 a 7 Hz. Esse tipo de tremor é episódico, podendo ser

suprimido ou aumentado por atividades motoras ou cognitivas. Inclusive, pessoas saudáveis podem apresentar oscilações musculares, denominadas tremores fisiológicos. Esses tremores são caracterizados por uma ação bilateral dos membros superiores, com frequência de 8 a 12 Hz e costumam ser mais intensificados por fadiga, estresse, ansiedade e certos medicamentos [4-6].

Embora o tremor não apresente um risco iminente à vida, é amplamente reconhecido como um distúrbio altamente debilitante que pode limitar significativamente a capacidade dos indivíduos de executar atividades cotidianas, como escrever, escovar os dentes e comer. Além disso, a cura para a maioria das causas do tremor ainda não está disponível, mas, é possível realizar intervenções para controlar seus sintomas. O tratamento do tremor é determinado pela sua causa subjacente e pode abranger terapias medicamentosas, fisioterapia, mudanças no estilo de vida ou cirurgias, especialmente quando outras abordagens terapêuticas se mostram ineficazes [1].

Além das terapias citadas anteriormente, observa-se uma crescente demanda por tecnologias que possam contribuir para a supressão dos tremores e, conseqüentemente, uma melhoria da qualidade de vida dos pacientes de forma menos invasiva. Nesse contexto, as tecnologias de assistência robótica têm sido objeto de extensa investigação, com o propósito de desenvolver dispositivos que possam prestar auxílio nas atividades do dia a dia [7]. Uma alternativa adotada para mitigar os tremores nas mãos é a utilização de dispositivos eletrônicos que empregam algoritmos adaptativos. Esses dispositivos recebem um sinal de entrada e geram um sinal de saída que neutraliza os tremores, permitindo que o indivíduo realize suas atividades com maior eficácia e conforto [8-10].

Van e Ngo conceberam um dispositivo vestível baseado em giroscópio, posicionado nas costas da mão do usuário, obtendo resultados de simulações com uma eficácia de 92,6% na redução dos tremores em [11]. Além dessa, uma solução para controlar os tremores nas mãos de pessoas com doença de Parkinson, fazendo uso de controladores proporcional e de lógica fuzzy foi apresentado em [12]. Testes com uma mesa agitadora orbital<sup>1</sup> e acelerômetro demonstraram uma redução de até 88,39% nos tremores ao transferir um sinal para um atuador na palma da mão. O estudo de [13] descreveu um dispositivo não invasivo para redução de tremores em pacientes

<sup>1</sup>A mesa agitadora orbital é um equipamento de laboratório comumente utilizado em diversos segmentos industriais.

com Parkinson, utilizando sensor de movimento, microcontrolador com controle fuzzy PI e dois atuadores. Simulações com dados reais de pacientes indicaram que o dispositivo pode atenuar até 75% dos tremores no eixo Z e até 35% no eixo X. Por sua vez, o estudo realizado por [9] abordou o emprego de algoritmos adaptativos para controlar tremores nas mãos, empregando o Fx-LMS, Fx-NLMS e Fx-NLMS&LMS em simulações com sinais de tremores simulados no MATLAB, demonstrando a eficácia dos algoritmos. O Fx-NLMS&LMS se destacou por sua rápida convergência em tremores fisiológicos (cerca de 4000 amostras), enquanto o Fsinx-LMS foi mais eficaz em tremores patológicos.

Os algoritmos adaptativos constituem uma classe de algoritmos projetados para se adaptarem ao ambiente em que estão inseridos e aos dados que estão sendo processados. Esses são capazes de solucionar problemas em sistemas, séries temporais, controle de processos e muitos outros contextos, sendo, portanto aplicados em diversas áreas, abrangendo o controle de sistemas, a inteligência artificial, o processamento de sinais, entre outras [14–16].

É relevante ressaltar que este estudo não envolveu testes em seres humanos. Este trabalho tem como finalidade a condução de uma análise comparativa entre diversos algoritmos adaptativos voltados para o controle ativo das vibrações, visando à redução dos tremores nas mãos dos usuários. Para a avaliação do desempenho de cada método, serão utilizados indicadores como o *Mean Square Error* (MSE), tempo de convergência e complexidade. Para a condução das simulações, optou-se por empregar o conjunto de dados denominado NewHandPD [17], que inclui registros de tremores nas mãos de 66 indivíduos, sendo 35 com condição de saúde normal e 31 diagnosticados com a doença de Parkinson. Esses registros foram obtidos por meio do uso de uma caneta equipada com um acelerômetro, enquanto os pacientes executavam tarefas de desenho, como círculos e espirais.

As demais seções deste trabalho estão organizadas como se segue. Uma revisão abrangente de algoritmos adaptativos é apresentada na Seção 2. A análise crítica e sistemática desses algoritmos oferece uma base sólida para compreensão e seleção adequada de métodos eficazes no controle de sistemas vibratórios. Na Seção 3, é detalhado o ambiente proposto para a realização dos testes experimentais, oferecendo *insights* importantes sobre as condições controladas e as variáveis envolvidas. Os resultados desses testes e suas implicações são discutidos na Seção 4, destacando as respostas do sistema sob diferentes cenários e condições experimentais. A análise crítica dos resultados proporciona uma compreensão aprofundada do desempenho dos algoritmos adaptativos no contexto específico do controle de vibração. Por fim, na Seção 5, são apresentadas as conclusões derivadas dos achados, destacando as contribuições significativas, limitações identificadas e possíveis direções futuras para a pesquisa nesse campo crucial da engenharia de controle de vibração. Este estudo busca contribuir para o entendimento sobre a eficácia de algoritmos adaptativos no controle ativo de vibração para futuros desenvolvimentos e aplicações práticas.

## 2 CONTROLE ATIVO DE VIBRAÇÃO

O Controle Ativo de Vibração (do inglês *Active Vibration Control* – AVC) é uma técnica aplicada para o controle de vibrações externas em máquinas e estruturas. Essas vibrações podem causar fadiga e

ruídos indesejados, tornando o controle de vibração crucial para manter um desempenho adequado. Diferentemente do amortecimento passivo, o AVC utiliza a aplicação ativa de forças iguais e opostas às forças geradas na vibração externa [18].

Um sistema AVC típico é composto por uma planta, sensores, atuadores e um controlador responsável pelo processamento de sinais e geração de forças de controle. A Figura 1 ilustra um sistema típico de AVC. Esse sistema é totalmente ativo, o que significa que o atuador introduz forças de controle conforme o sensor mede a vibração [19]. Além disso, podem ser utilizadas fundamentalmente duas abordagens para lidar com as vibrações: *feedforward* e *feedback*. Na abordagem de *feedforward*, os erros são previstos e corrigidos antecipadamente, antes mesmo de ocorrerem. Já na abordagem de *feedback*, os erros são ajustados à medida que ocorrem [20].

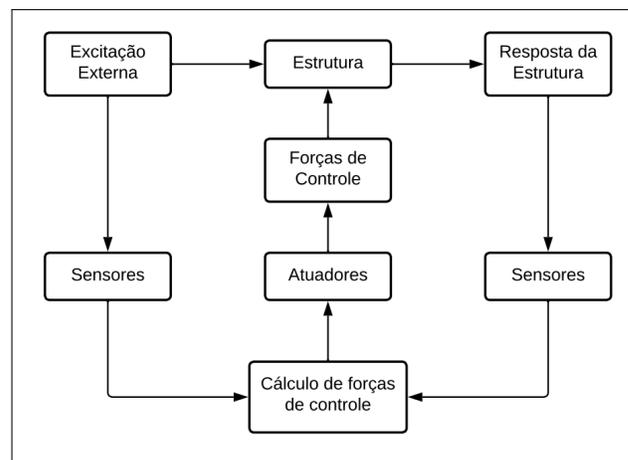


Figura 1: Representação de um sistema AVC.

O AVC é particularmente útil em vibrações de baixa frequência, onde o uso de amortecimento passivo pode não ter um efeito significativo. A aplicação do AVC permite que as máquinas e estruturas operem com baixos níveis de vibração, o que leva a uma redução de tensões, fadiga e ruído. Portanto, o AVC é uma tecnologia viável e eficaz para melhorar o desempenho de muitos sistemas industriais [18, 20].

### 2.1 Algoritmos adaptativos

Os algoritmos adaptativos são amplamente utilizados em aplicações que envolvem sinais cujas propriedades estatísticas são desconhecidas ou variantes no tempo. Ao contrário dos algoritmos com coeficientes fixos, que possuem parâmetros internos predefinidos e não se adaptam ao ambiente em que são aplicados, os algoritmos adaptativos são capazes de ajustar automaticamente seus parâmetros internos (coeficientes ou taxa de aprendizado) de acordo com as características do sinal de entrada, otimizando assim o seu desempenho. Além disso, podem ser aplicados em sistemas que requerem o processamento em tempo real, tais como, telecomunicações, engenharia biomédica, entre outras [21, 22].

**A – Least-Mean-Square (LMS).** O algoritmo LMS foi proposto por Widrow e Hoff em 1960 e é o algoritmo adaptativo mais utilizado [21]. A ampla adoção do LMS pode ser justificada devido à sua baixa complexidade computacional, à prova de convergência em ambiente estacionário, à convergência imparcial na média para a solução de Wiener, ao comportamento estável quando implementado com aritmética de precisão finita e à simplicidade [21, 23].

A atualização do vetor de pesos é dada por:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + 2\eta e_n \mathbf{x}_n \quad (1)$$

em que  $\mathbf{w}_n$  representa o vetor de coeficientes do filtro na  $n$ -ésima iteração,  $\eta$  é a taxa de aprendizado e controla a velocidade de adaptação do filtro,  $\mathbf{x}_n$  é o sinal de entrada na  $n$ -ésima iteração e  $e_n$  é a  $n + 1$ -ésima observação do erro obtido pela diferença entre  $y_n$  (saída do filtro adaptativo ou sinal estimado) e o sinal desejado  $d_n$ , isto é,

$$e_n = d_n - y_n. \quad (2)$$

Em (2) a saída do filtro adaptativo é dada por:

$$y_n = \mathbf{w}_n^\top \mathbf{x}_n. \quad (3)$$

**B – Normalized Least Mean Square (NLMS).** O algoritmo NLMS é uma variação do algoritmo LMS que leva em consideração a variação da potência do sinal de entrada do filtro e calcula um parâmetro de tamanho de passo normalizado, resultando em um algoritmo de adaptação de convergência rápida e estável [21].

Considera-se o algoritmo LMS, no qual a equação de ajuste dos coeficientes é dada por (1). Nessa equação, a taxa de aprendizagem  $\eta$  é frequentemente definida como uma constante fixa. No entanto, no algoritmo NLMS, esse valor será variável ao longo do tempo. Como resultado, a equação correspondente será ajustada para incorporar essa variação temporal.

Uma vez que a taxa de aprendizado é variável ao longo do tempo, é necessário calcular o erro a posteriori, aqui denotado por  $e^+$  usa-se:

$$e_n^+ = d_n - \mathbf{w}_{n+1}^\top \mathbf{x}_n. \quad (4)$$

Substituindo (1) em (4), obtém-se:

$$e_n^+ = (1 - 2\eta \mathbf{x}_n^\top \mathbf{x}_n) e_n. \quad (5)$$

A taxa de aprendizado variável  $\eta$  é dada por:

$$\eta_n = \frac{1}{\xi + \|\mathbf{x}_n\|^2}. \quad (6)$$

em que  $\xi \in \mathbb{R}$  é uma constante pequena,  $\xi \approx 10^{-10}$ , definida pelo usuário para evitar a divisão por zero.

Assim, obtém-se a seguinte equação para a atualização dos coeficientes:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + \frac{1}{\xi + \|\mathbf{x}_n\|^2} e_n \mathbf{x}_n. \quad (7)$$

**C – Filtered Least Mean Squared (Fx-LMS).** Embora o algoritmo LMS seja caracterizado por sua simplicidade e facilidade de implementação, não é uma escolha ideal para aplicações que demandam um controle ativo de vibração em tempo real, devido ao seu longo atraso que resulta na operação do filtro com amostras anteriores. Em resposta a essa limitação, [24] propôs uma solução alternativa que envolve a adaptação do filtro ao sinal de frequência. Posteriormente, é realizada uma comparação entre o sinal de entrada e o sinal filtrado, possibilitando a obtenção do sinal estimado.

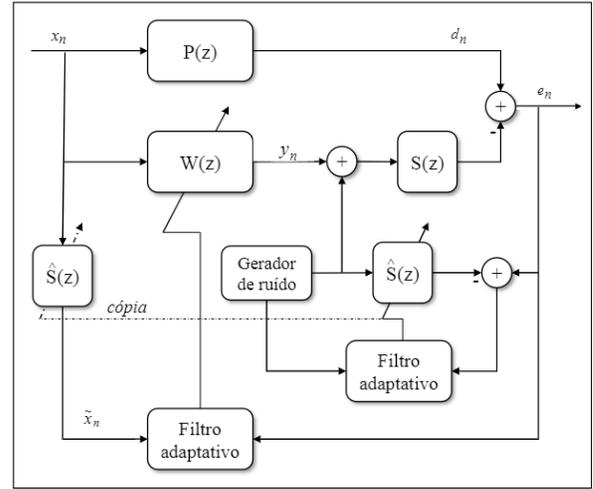
No filtro adaptativo Fx-LMS, a equação para o cálculo dos coeficientes atualizados é dada por:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + \eta e_n \tilde{\mathbf{x}}_n \quad (8)$$

em que  $\tilde{\mathbf{x}}_n$  é a entrada filtrada, que pode ser obtida a partir de

$$\tilde{\mathbf{x}}_n = \sum_{i=0}^{N-1} \hat{s}_i \mathbf{x}_{n-i}. \quad (9)$$

Em (9),  $\hat{s}_n$  representa o valor estimado de  $s_n$ , que corresponde à planta na linha secundária. A Figura 2 apresenta uma representação gráfica do funcionamento básico de um sistema de AVC usando uma estrutura baseada na filtragem do sinal de entrada.



**Figura 2: Esquemática base do controle ativo de vibração usando algoritmos baseados em filtragem do sinal de entrada.**

O esquema de AVC, conforme evidenciado na Figura 2, fundamenta-se essencialmente em um sistema composto por planta (coeficientes que definem o comportamento do sistema dinâmico). Os sinais são representados pelos blocos  $\mathbf{x}(n)$  entrada do sistema e é empregado para a identificação dos coeficientes da planta da malha principal (caminho direto), enquanto o gerador de ruído corresponde a um sinal anti-sinal gerado na malha secundária, utilizado para a identificação dos coeficientes do filtro  $S(z)$ . O sinal  $\mathbf{x}(n)$  é empregado para o reconhecimento dos coeficientes da planta da malha principal (caminho direto)  $W(z)$ . Por outro lado, o gerador de ruído representa um anti-sinal gerado na malha secundária para o reconhecimento dos coeficientes do filtro  $S(z)$ . Para controlar o sinal de tremor fisiológico, a planta de  $S(z)$  deve seguir um modelo proporcional a  $P(z)$ .

**D – Filtered Normalized Least Mean Square (Fx-NLMS).** Assim como acontece com o algoritmo LMS, que possui uma forma normalizada, existe uma versão normalizada específica para o algoritmo adaptativo Fx-LMS chamada Fx-NLMS. Semelhante ao algoritmo NLMS, o Fx-NLMS segue o mesmo princípio e tem como objetivo aprimorar a velocidade de convergência, além de possuir uma capacidade adaptativa e robustez poderosas.

A diferença entre os dois algoritmos está presente no cálculo da atualização dos coeficientes. Enquanto o algoritmo Fx-LMS possui um passo de aprendizado fixo, no algoritmo Fx-NLMS esse valor varia ao longo do tempo, conforme pode ser observado na Equação:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + \frac{1}{\xi + \|\tilde{\mathbf{x}}_n\|^2} e_n \tilde{\mathbf{x}}_n. \quad (10)$$

**E – Fx-LMS&NLMS.** O algoritmo híbrido Fx-NLMS&LMS usa em sua estrutura de controle dois algoritmos Fx-NLMS e o Fx-LMS, considerando os dados normalizados no erro da malha secundária. Este arranjo foi apresentado [9] produzindo bons resultados por utilizar passos de adaptação diferentes  $\eta$  e  $\eta_s$  nas Equações (8) e (10), respectivamente.

**F – Recursive Least Squares (RLS).** O algoritmo RLS também é amplamente utilizado no processamento de sinais, assim como o LMS. No entanto, eles apresentam diferenças significativas em termos de velocidade de convergência e complexidade computacional. Enquanto o LMS é relativamente simples e fácil de ser implementado, o RLS demanda um custo computacional maior; no entanto, isso resulta em uma velocidade de convergência maior [21–23].

Durante a execução do algoritmo RLS, a matriz de covariância é atualizada a cada iteração por meio da seguinte equação:

$$\mathbf{P}_{\lambda; n}^{-1} = \lambda^{-1} \left[ \mathbf{P}_{\lambda; n-1}^{-1} - \mathbf{k}_n \left( \mathbf{x}_n^T \mathbf{P}_{\lambda; n-1}^{-1} \right) \right] \quad (11)$$

em que  $\mathbf{P}_{\lambda; n}^{-1}$  denota a  $n$ -ésima matriz de covariância inversa,  $\lambda$  representa o passo de esquecimento e  $\mathbf{k}_n$  representa o ganho de Kalman. O ganho de Kalman pode calculando a partir de:

$$\mathbf{u}_n = \mathbf{P}_{\lambda; n-1}^{-1} \mathbf{x}_n \quad (12)$$

$$\mathbf{k}_n = \frac{1}{\lambda + \mathbf{x}_n^T \mathbf{u}_n} \mathbf{u}_n. \quad (13)$$

Para atualizar o vetor de coeficientes do filtro adaptativo, utiliza-se o ganho de Kalman  $\mathbf{k}_n$  e o erro  $e_n$ , obtendo-se a equação a seguir:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + \mathbf{k}_n e_n. \quad (14)$$

**G – Filtro de Kalman.** O filtro de Kalman foi descrito pela primeira vez em 1960 por Rudolf Emil Kalman em [25] e desde então tem sido amplamente aplicado em áreas como navegação autônoma ou assistida. Este filtro é capaz de fornecer uma solução recursiva para o problema de filtragem ótima linear em ambientes tanto estacionários quanto não estacionários [26].

O filtro de Kalman é composto por duas etapas: a etapa de predição e a etapa de correção. Na etapa de predição, realiza-se o cálculo da propagação da estimativa de estado e da covariância de erro. As equações correspondentes a esses cálculos podem ser observadas, respectivamente, por meio de:

$$\hat{\mathbf{y}}_n^- = \mathbf{F}_{n,n-1} \hat{\mathbf{y}}_{n-1}^- \quad (15)$$

$$\mathbf{P}_n^- = \mathbf{F}_{n,n-1} \mathbf{P}_{n-1}^- \mathbf{F}_{n,n-1}^T + \mathbf{Q}_{n-1} \quad (16)$$

em que  $\hat{\mathbf{y}}_n^-$  corresponde à estimativa atualizada do estado do sistema no  $n$ -ésimo instante (dada a medição realizada no  $n$ -ésimo instante de tempo),  $\mathbf{F}_{n,n-1}$  é a matriz de transição de estado que relaciona o estado atual ( $n-1$ ) com o próximo estado ( $n$ ),  $\hat{\mathbf{y}}_{n-1}^-$  é a estimativa de estado no  $n$ -ésimo instante de tempo (dadas as informações disponíveis no  $(n-1)$ -ésimo instante de tempo),  $\mathbf{P}_n^-$  é a matriz

covariância da estimativa do estado predito e  $\mathbf{Q}_{n-1}$  é a matriz de ruído do processo.

A segunda etapa do filtro de Kalman é a correção. Nessa etapa o ganho de Kalman é calculado como sendo:

$$\mathbf{k}_n = \mathbf{P}_n^- \mathbf{H}_n^T [\mathbf{H}_n \mathbf{P}_n^- \mathbf{H}_n^T + \mathbf{R}_n]^{-1} \quad (17)$$

em que  $\mathbf{H}_n$  representa a matriz de observação que relaciona o estado do sistema com a medição realizada no  $n$ -ésimo instante de tempo e  $\mathbf{R}_n$  é a matriz de covariância do ruído da medição.

Após o cálculo do ganho de Kalman, esse valor é utilizado para realizar os cálculos da atualização do estado de covariância e da estimativa de covariância, dadas respectivamente por:

$$\hat{\mathbf{y}}_n = \hat{\mathbf{y}}_n^- + \mathbf{k}_n (\mathbf{x}_n - \mathbf{H}_n \hat{\mathbf{y}}_n^-) \quad (18)$$

$$\mathbf{P}_n = (\mathbf{I} - \mathbf{k}_n \mathbf{H}_n) \mathbf{P}_n^- \quad (19)$$

em que  $\mathbf{k}_n$  é o ganho de Kalman, responsável por determinar o peso que será dado à medição atual na atualização da estimativa do estado, a variável  $\mathbf{x}_n$  representa a medição realizada no instante de tempo  $n$  e  $\mathbf{I}$  representa a matriz identidade.

### 3 AMBIENTE PROPOSTO PARA TESTE

Nesta seção serão apresentadas as configurações utilizadas para realizar as simulações e validar o funcionamento de cada um dos algoritmos adaptativos abordados. Com base na pesquisa conduzida em [9], optou-se pela seleção dos algoritmos Fx-LMS, Fx-NLM e Fx-NLMS&LMS para simulação, uma vez que foi demonstrada a eficácia desses algoritmos adaptativos na atenuação dos tremores das mãos. No estudo mencionado, foram empregados sinais de tremores sintéticos gerados a partir de modelos matemáticos. Em contrapartida, neste trabalho, foram utilizados sinais reais de pacientes com doença de Parkinson. Além disso, os algoritmos RLS e Filtro de Kalman também foram escolhidos devido ao desempenho em sinais temporais e à rápida convergência que proporcionam.

Para a realização das simulações, foram utilizados os sinais dos tremores das mãos de 31 pacientes com doença de Parkinson, disponíveis no conjunto de dados NewHandPD [17]. Os dados foram coletados por meio de uma caneta eletrônica que possuía um acelerômetro associado a um microcontrolador para capturar os sinais dos tremores enquanto os pacientes desenhavam espirais. Na Figura 3, é possível visualizar exemplos das espirais desenhadas pelos pacientes.

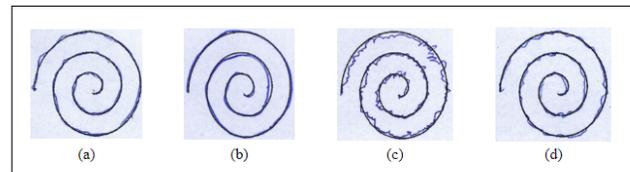


Figura 3: Exemplos de espirais extraídas do conjunto de dados NewHandPD. Fonte: [17].

Os sinais disponíveis foram analisados utilizando os algoritmos adaptativos selecionados, que foram implementados utilizando a linguagem de programação Python, para determinar qual deles apresentaria a melhor resposta no processamento desses sinais de entrada. Para as simulações, foram utilizados na implementação

filtros com uma planta de dimensão  $2 \times 1$ , ou seja,  $N = 2$ , essa escolha inicial considerada a partir de [9]. Foram utilizadas 3000 amostras de cada paciente para cada algoritmo testado. Além disso, foram realizados alguns testes prévios – considerando o desempenho em regime permanente do erro quadrático médio e o tempo para convergência – para o ajuste ótimo dos parâmetros dos filtros testados, isto é,  $\eta$  para os algoritmos Fx-LMS e Fx-NLMS;  $\eta$  e  $\eta_s$  para o algoritmo Fx-NLMS&LMS na Tabela 1. Após a definição dos valores das constantes utilizadas em cada algoritmo, as simulações foram iniciadas. Em todos os testes foi considerado um ruído branco – *White Gaussian Noise* (WGN) com média  $\mu = 0$  e variância  $\sigma^2 = 10^{-4}$  – nos experimentos.

Tabela 1: Sumário das constantes utilizadas nas simulações.

Algoritmo	$\eta$	$\eta_s$	$\lambda$
Fx-LMS	0,0005	-	-
Fx-NLMS	0,008	-	-
Fx-NLMS&LMS	0,005	0,008	-
RLS	-	-	0,999
Kalman	-	-	0,999

#### 4 RESULTADOS

A Figura 4 representa os resultados obtidos pelos algoritmos quando operando com os parâmetros apresentados na Tabela 1. É possível notar as tendências de cada um dos algoritmos, bem como a velocidade de convergência –  $n_\infty$  – e o MSE em regime permanente –  $J_{ms_\infty}$ . Além disso, é possível notar que os algoritmos RLS e o filtro de Kalman tiveram o melhor desempenho dentre os algoritmos testados. Embora com um transitório mais lento do que o filtro de Kalman, o algoritmo RLS atingiu o mais baixo erro quadrático médio em regime permanente.

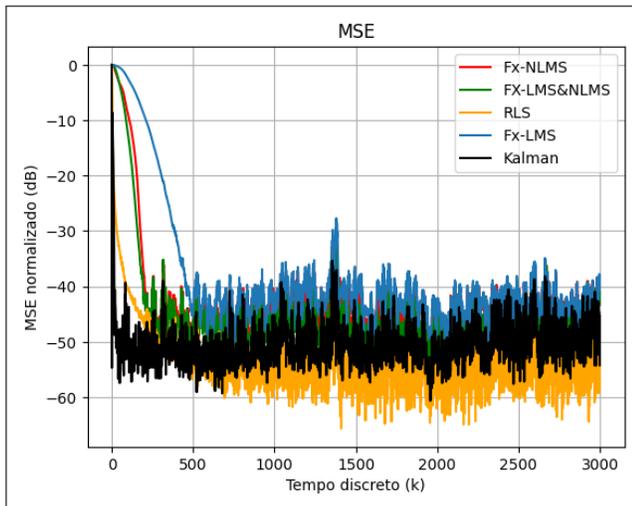


Figura 4: Comparativo do MSE normalizado dos algoritmos testados.

A Tabela 2 apresenta uma sumarização dos resultados relacionados ao comportamento do erro quadrático médio (MSE) em

regime permanente, denotado por  $J_{ms_\infty}$ , bem como o tempo médio necessário para a convergência, representado por  $n_\infty$ .

Tabela 2: Sumário dos resultados obtidos nas simulações dos algoritmos adaptativos.

Algoritmo	$J_{ms_\infty}$ (dB)	$n_\infty$ (iterações)
Fx-LMS	-38	600
Fx-NLMS	-42	400
Fx-NLMS&LMS	-44	350
RLS	-53	300
Filtro de Kalman	-50	50

Uma análise comparativa revelou que o algoritmo Fx-LMS e o filtro de Kalman apresentaram diferenças significativas em termos de taxa de convergência. O filtro de Kalman demonstrou uma convergência 12 vezes mais rápida em relação ao Fx-LMS. No contexto do algoritmo Fx-NLMS, o filtro de Kalman exibiu um tempo de convergência 8 vezes superior. De maneira similar, quando comparado ao algoritmo Fx-NLMS&LMS, o filtro de Kalman demonstrou uma taxa de convergência superior em 7 vezes. Em relação ao algoritmo RLS, o filtro de Kalman superou-o, alcançando uma velocidade de convergência 6 vezes maior. Portanto, embora o algoritmo RLS tenha apresentado o menor MSE em regime permanente, o filtro de Kalman mostrou um desempenho superior ao atenuar os tremores de forma mais rápida. Para o usuário, essa abordagem é mais vantajosa, pois permite uma redução mais rápida dos tremores, mesmo que haja uma perda na acurácia.

As Figuras 5 e 6 apresentam o comportamento de rastreamento da solução. Nestas a representação em azul representa o sinal de tremor e o sinal de saída gerado respectivamente pelos algoritmos RLS e Kalman, é representado em vermelho.

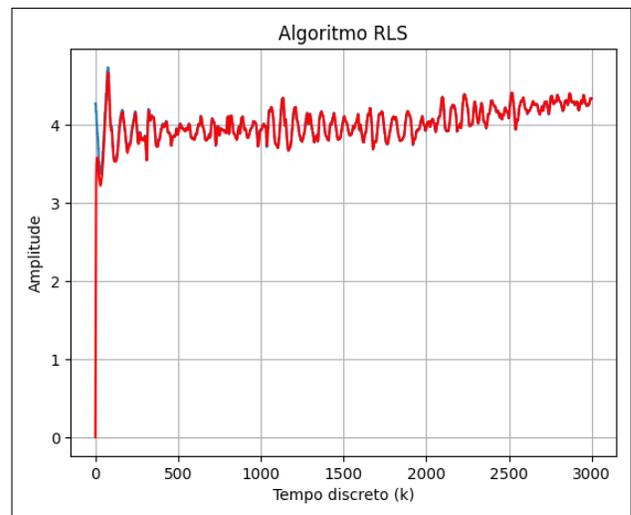


Figura 5: Resultado obtido na simulação do RLS.

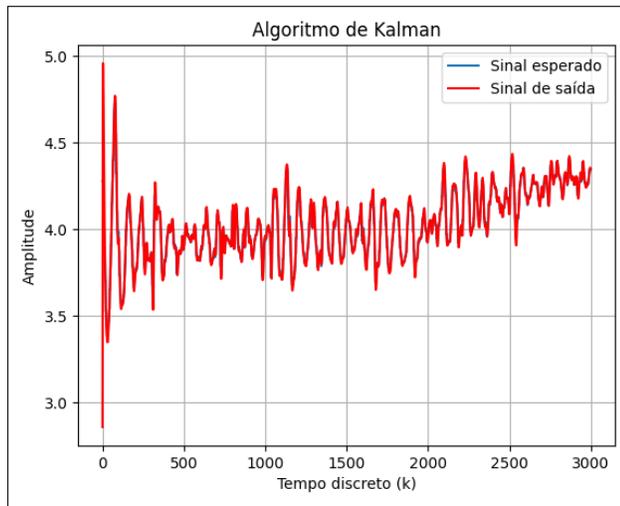


Figura 6: Resultado obtido na simulação do filtro de Kalman.

## 5 CONCLUSÃO

Neste trabalho, foi realizada uma análise detalhada dos algoritmos adaptativos e um comparativo entre eles com o objetivo de identificar o melhor desempenho entre os algoritmos selecionados na tarefa de atenuação dos tremores das mãos. O estudo envolveu a condução de simulações utilizando o conjunto de dados NewHandPD, possibilitando a avaliação de cada algoritmo no contexto específico da atenuação de tremores.

Após a simulação dos algoritmos adaptativos e a análise dos resultados, observou-se o desempenho desses algoritmos na filtragem dos sinais de entrada. Ao analisar o MSE, verificou-se que o algoritmo RLS foi capaz de ajustar os coeficientes de maneira mais precisa e eficiente, resultando em uma estimativa mais próxima do sinal desejado. No entanto, é importante destacar que o filtro de Kalman apresentou uma convergência mais rápida durante o processo de adaptação, em relação ao algoritmo RLS, que possui o menor MSE em regime permanente, o Kalman conseguiu convergir 6 vezes mais rápido. Além disso, em comparação com os outros algoritmos adaptativos simulados, o Kalman alcançou uma velocidade de convergência ainda maior. Essa capacidade de adaptação rápida e precisa do filtro de Kalman é uma característica importante para a experiência de uso de dispositivos eletrônicos implementados com este algoritmo, permitindo uma resposta mais ágil e eficiente aos movimentos do usuário.

## REFERÊNCIAS

[1] NIH. Tremor. 2023. Disponível em: <<https://www.ninds.nih.gov/health-information/disorders/tremor>>.

[2] GONZALEZ-USIGLI, H. Tremor. 2022. Disponível em: <<https://www.msmanuals.com/professional/neurologic-disorders/movement-and-cerebellar-disorders/tremor>>.

[3] SHARMA, S.; PANDEY, S. Approach to a tremor patient. *Ann Indian Acad Neurol*, v. 19, n. 4, p. 433–443, 2016. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5144461/>>.

[4] PAHWA, R. et al. An acute randomized controlled trial of noninvasive peripheral nerve stimulation in essential tremor. *Neuromodulation*, v. 22, n. 5, p. 537–545, 2019. Disponível em: <[https://www.neuromodulationjournal.org/article/S1094-7159\(21\)01976-0/fulltext](https://www.neuromodulationjournal.org/article/S1094-7159(21)01976-0/fulltext)>.

[5] DOVZHENOK, A.; RUBCHINSKY, L. L. On the origin of tremor

in parkinson's disease. *PLoS One*, v. 7, n. 7, 2012. Disponível em: <<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0041598>>.

[6] BORGES, V.; FERRAZ, H. B. Tremores. *Revista Neurociências*, v. 14, n. 1, p. 43–47, 2006. Disponível em: <<https://periodicos.unifesp.br/index.php/neurociencias/article/view/8786/6320>>.

[7] LORA-MILLAN, J. S. et al. A review on wearable technologies for tremor suppression. *Frontiers in Neurology*, v. 12, 2021. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fneur.2021.700600/full>>.

[8] ARAÚJO, R. S. A.; PARREIRA, W. D.; BORGES, R. C. Análise comparativa de algoritmos adaptativos baseados em least-mean-square para o controle ativo de vibração. *Anais do Computer on the Beach*, v. 14, p. 303–310, 2023.

[9] ARAUJO, R. S. A. et al. Analysis of adaptive algorithms based on least mean square applied to hand tremor suppression control. *Applied Sciences*, v. 13, n. 5, 2023. Disponível em: <<https://www.mdpi.com/2076-3417/13/5/3199>>.

[10] CASTRILLO-FRAILE, V. et al. Tremor control devices for essential tremor: A systematic literature review. *Tremor and Other Hyperkinetic Movements*, v. 9, n. 0, 2019. Disponível em: <<https://tremorjournal.org/articles/10.5334/tohm.511>>.

[11] VAN, H. P.; NGO, H. Q. T. Developing an assisting device to reduce the vibration on the hands of elders. *Applied Sciences*, v. 11, n. 11, 2011. Disponível em: <<https://www.mdpi.com/2076-3417/11/11/5026>>.

[12] JAMALUDIN, H. B. et al. Active tremor control in human-like hand tremor using fuzzy logic. *Indonesian Journal of Electrical Engineering and Computer Science*, v. 24, n. 1, p. 108–115, 2021. Disponível em: <<https://ijeecs.iaescore.com/index.php/IJECS/article/view/25103>>.

[13] TALAEI, F.; KARGAR, S. M. Design and fabrication of a device for reducing hand tremor in parkinson patients during eating. *Journal of medical signals and sensors*, v. 13, n. 1, p. 21–28, 2021. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10246595/>>.

[14] INGLE, V.; KOGON, S.; MANOLAKIS, D. *Statistical and Adaptive Signal Processing*. [S.l.]: ARTECH HOUSE: Boston, MA, USA, 2005.

[15] NASCIMENTO, V. H.; SILVA, M. T. Adaptive filters. In: *Academic Press Library in Signal Processing*. [S.l.]: Elsevier, 2014. v. 1, p. 619–761.

[16] SANTOS, V. A. D. et al. Improving speaker recognition in environmental noise with adaptive filter. *IEEE Access*, IEEE, v. 10, p. 124523–124533, 2022.

[17] PEREIRA, C. R. et al. Deep learning-aided parkinson's disease diagnosis from handwritten dynamics. In: *2016 29th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. [S.l.: s.n.], 2016. p. 340–346.

[18] PREUMONT, A. *Vibration Control of Active Structures: An Introduction*. [S.l.]: Springer Netherlands, 2006. (Solid Mechanics and Its Applications).

[19] KIM, S.-M.; KIM, D. W.; KWAK, M. K. Design and implementation of an active vibration control algorithm using servo actuator control installed in series with a spring-damper. *Applied Sciences*, v. 13, n. 5, 2023. Disponível em: <<https://www.mdpi.com/2076-3417/13/5/3349>>.

[20] MLJKOVIĆ, D. Review of active vibration control. *Croatian Society for Information and Communication*, p. 103–108, 2009.

[21] DINIZ, P. S. R. *Adaptive Filtering*. [S.l.]: Springer, 2012.

[22] BULL, D. R. et al. *Academic Press Library in Signal Processing: Image and Video Compression and Multimedia*. [S.l.]: Elsevier Science, 2014.

[23] FARHANG-BOROJENY, B. *Adaptive Filters: Theory and Applications*. 2. ed. [S.l.]: Wiley, 2013.

[24] WIDROW, B. et al. Adaptive noise cancelling: Principles and applications. *Proceedings of the IEEE*, v. 63, n. 12, p. 1692–1716, 1975. Disponível em: <<https://ieeexplore.ieee.org/document/1451965>>.

[25] KALMAN, R. E. A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, v. 82, n. 1, p. 35–45, 1960. Disponível em: <<https://asmedigitalcollection.asme.org/fluidengineering/article-abstract/82/1/35/397706/A-New-Approach-to-Linear-Filtering-and-Prediction?redirectedFrom=fulltext>>.

[26] WELCH, G.; BISHOP, G. *An Introduction to the Kalman Filter*. 2006. Disponível em: <[https://www.cs.unc.edu/welch/media/pdf/kalman\\_intro.pdf](https://www.cs.unc.edu/welch/media/pdf/kalman_intro.pdf)>.