

Análise Comparativa de Algoritmos Adaptativos Baseados em Least-Mean-Square para o Controle Ativo de Vibração

Rafael Silfarney Alves Araújo

silfarney@live.com

Universidade do Vale do Itajaí

Itajaí, Santa Catarina, BRA

Wemerson Delcio Parreira

parreira@univali.br

Universidade do Vale do Itajaí

Itajaí, Santa Catarina, BRA

Renata Coelho Borges

Universidade Tecnológica Federal do

Paraná

Cornélio Procópio, Paraná, BRA

ABSTRACT

Adaptive algorithms have been applied in noise and vibration suppression in several engineering areas. This work investigates the practicality of analysis between techniques of active vibration control for the suppression of movements arising from hand tremors. The signals generated by the pathological motion have frequencies between 3Hz and 6Hz, with the highest concentration of energy in the gestures. These signals are acquired in the fundamental harmonic and the second harmonic, whereas physiological tremors vary between 2Hz and 12Hz. We have used computational tools in Matlab to simulate these signals. We have used the least mean square (LMS) based algorithms, namely Filtered-x Least Mean Square (Fx-LMS), Filtered-x Normalized Least Mean Square (Fx-NLMS), and a hybrid Fx-NLMS&LMS. In our results, we identify a faster response by the Fx-LMS&LMS algorithm in the active vibration control for physiological tremors. In this example, the algorithm has required 3000 samples for steady-state.

KEYWORDS

adaptive filtering, active control, LMS algorithm, hands tremor

1 INTRODUÇÃO

Segundo dados da Organização Mundial da Saúde (OMS), pessoas nascidas em 2015 terão em média 20 anos a mais de expectativa de vida do que pessoas nascidas há 50 anos, em boa parte do mundo, incluindo o Brasil [1]. Com o aumento da expectativa de vida, há também um aumento na incidência de patologias inerentes ao envelhecimento. Pessoas acima dos 60 anos são normalmente acometidas por doenças neurológicas que causam tremores [2], que são movimentos oscilatórios causados de forma involuntária em alguma parte do corpo [3].

Tremores Essenciais (TE) figuram como uma das doenças neurológicas mais predominantes no mundo. Estima-se que cerca de 1% da população mundial e aproximadamente 6,4% de pessoas acima de 65 anos de idade sofram de TE [4]. A segunda maior patologia causadora de tremores involuntários é a doença Parkinson (DP). Pessoas que Sofrem de DP e TE têm dificuldades de realizarem tarefas simples do cotidiano como comer e escrever, por exemplo.

Os tremores podem ser classificados como tremor em ação e tremor em repouso [5]. O tremor essencial está mais predominantemente relacionado à ação e atinge membros superiores do corpo, como mãos e cabeça, possuindo características de frequência que variam de 4 Hz a 12 Hz [6]. Este tipo de tremor pode ser bilateral ou simétrico [7]. Já os tremores em repouso, na maioria dos casos, estão relacionados a Doença de Parkinson, que ocorre quando o membro do paciente está totalmente relaxado e sem que haja um

esforço anti-gravitacional. Nesse caso, são produzidos movimentos indesejados tanto em membros inferiores quanto em membros superiores, na faixa de frequência entre 3 Hz e 6 Hz [7].

As alternativas mitigatórias convencionais para esses pacientes estão atreladas à medicamentos e à intervenção cirúrgica. Para o tratamento com a medicação Levodopa, por exemplo, foi observado que cerca de 50% dos pacientes, após 5 anos de tratamento, apresentaram algum tipo de efeito colateral como agitação, alucinação, alterações de humor e impulsividade [8, 9]. Outra forma de tratamento é a intervenção cirúrgica mas, em alguns casos, as pessoas além de sofrerem da DP, sofrem de hipertensão arterial sistêmica, correndo riscos de hemorragias graves nesses tipos de procedimento [10].

Visando a melhoria da qualidade de vida de pessoas que possuem DP e TE, vários dispositivos vêm sendo desenvolvidos de modo a aplicar técnicas de controle ativo, passivo e semiativo, para auxiliar a supressão de movimentos indesejados advindos dos tremores.

Controladores Proporcional Integrativo e Derivativo (PID) têm sido utilizados em pesquisas recentes sobre supressão de vibrações, em que os ganhos do controlador atuam para minimizar valores de sinais indesejados de modo a garantir que o ganho do sistema siga valores de referência [11]. Na análise proposta em [12], por exemplo, foi utilizado um modelo de mão humana com 4 graus de liberdade, juntamente com um atuador piezoelétrico, mostrando a viabilidade do emprego de controlador PID na supressão de vibrações da DP.

Os controladores podem ser fixos ou podem ser atualizados de acordo com algum algoritmo, como técnicas adaptativas. As técnicas de Filtros Adaptativos clássicas possuem uma ampla aplicabilidade no cancelamento de ruídos e ecos. Nesse sentido, [13] apresenta um *software* com uma interface capaz de mostrar a aplicabilidade de filtros adaptativos no cancelamento de eco acústico em tempo real. Esse software é denominado Ambiente de Testes de Filtros Adaptativos (ATFA).

Este trabalho apresenta um comparativo de técnicas adaptativas de controle ativo de vibração para supressão de movimentos oriundas de tremores essenciais das mãos considerando estudos de complexidade, tempo de convergência e *Mean Square Error* (MSE) em regime permanente. Sabendo que existem muitos desafios em pesquisas dessa natureza, especialmente na dificuldade da coleta e avaliação de dados de intensidade e frequência de tremores sem que seja necessário utilizar métodos invasivos, optou-se ainda pelo uso de modelos matemáticos e computacionais para analisar o efeito de atenuação de vibrações por algoritmos adaptativos. Portanto, não serão considerados nesse estudo testes em seres humanos. Neste caso, a análise de desempenho dos algoritmos de aprendizado estatístico testados envolvem apenas simulações de Monte Carlo.

O restante deste trabalho está organizado como se segue. Na Seção 2 é apresentado e discutido o modelo matemático usado para representar o sinal de tremor nas mãos. A Seção 3 apresenta uma a estrutura do controle ativo de vibração e os filtros usados para compor a solução do problema. A Seção 5 apresenta os resultados encontrados, bem como, uma discussão sobre os achados. Na Seção 6 são apresentadas as considerações finais e novos direcionamentos para a pesquisa na área.

1.1 Trabalhos relacionados

O controle ativo de vibração (*Active Vibration Control – AVC*) consiste na aplicação de uma força de intensidade oposta a uma fonte externa de vibração. Para reduzir o tremor da mão, Turkistani (2017) desenvolveu um protótipo de supressão de tremor que consiste em uma luva portátil e flexível. Este protótipo conta com um módulo de simulação de vibrações micro-eletró-mecânico baseado em acelerômetro-giroscópio embutido na luva que imita a vibração da mão. O sinal de vibração é coletado, enviado para um microcontrolador para que possa ser processado e ativa os motores de vibração presentes nos dedos para reduzir o tremor [14].

Outro método para eliminar o tremor do braço humano foi desenvolvido por Chuanasa e Songscho (2015), que usaram a técnica do auto-equilíbrio. Nessa técnica um atuador de massa desequilibrada rotativo foi empregado para reproduzir o tremor no braço com a mesma faixa de frequência obtida por fontes clínicas. Além da composição do dispositivo de contrabalanço projetado para prender o braço fictício, um controlador proporcional integral derivativo e um algoritmo programado no *LabVIEW* foram usados para controlar o atuador de massa desbalanceado rotativo, *anti-shaker*, a fim de combater o tremor [15].

Já o método utilizado por Hosseini et al. (2016) consiste em uma modelagem matemática de um sistema com 4 graus de liberdade de um sistema biomecânico que representa a mão humana. O controle ativo é feito pela combinação entre um controlador proporcional e derivativo e testados, via *MATLAB-Simulink*, em três tipos de atuadores diferentes: piezoelétrico, magnético e elétrico. Por fim comparou-se a eficiência de cada atuador separadamente, tendo o atuador piezoelétrico demonstrado uma maior eficiência na supressão dos tremores como os característicos do mal de Parkinson [16].

Conforme pode ser visto na Tabela 1, que apresenta um comparativo das técnicas encontradas na literatura que realizam o controle ativo de vibração considerando os últimos 7 anos, não há evidências de outras publicações tenham utilizado filtros adaptativos no controle de vibração de tremores associados à TE e PD. Nenhuma das técnicas encontradas apresentou aquisição de sinais.

Tabela 1: Quadro comparativo das publicações do tema nos últimos 7 anos.

Autor	Técnica	Controle
[17]	Rede neural	Ativo
[18]	Filtro adaptativo/controle interno	Ativo
[16]	Controle PID	Ativo
[15]	Controle PID/Filtro passa-baixa	Ativo
Este trabalho	Filtros adaptativos	Ativo

2 MODELOS MATEMÁTICOS DE TREMORES EM MEMBROS SUPERIORES

Neste trabalho é usado um modelo matemático de tremor nas mãos com semelhança com os padrões de sinais obtidos por meios clínicos e que sejam validados. Assim, elimina-se a necessidade da aquisição de sinais em seres humanos. Existem ainda vantagens de se utilizar modelos matemáticos como a fácil identificação, a boa resolução da frequência espectral e o uso conveniente em sistemas embarcados.

O método de caracterização utilizado Jakubowsk et al. (2002) na distinção entre tremores essenciais, fisiológicos e parkinsonianos, consiste em utilizar estatística de ordem superior por séries de Taylor, em que cumulantes de terceira e quarta ordem são implementadas para descrever o comportamento dos tremores. Além disso, afirma que os modelos Gaussianos de segunda ordem não são capazes de distinguir entre os três tipos de padrões vibratórios supracitados [19].

Já o modelo apresentado por Zhang e Chu (2005) consiste na simulação de tremores fisiológicos em uma mão estendida e carregada com peso de 2,3 a 4,5 kg, durante 60 segundos, por um modelo autorregressivo de ordem $p = 3$, $AR(3)$ [20].

Um processo autorregressivo de ordem p , $AR(p)$, é dado por:

$$\mathbf{x}(n) + \sum_{k=1}^p a_k \mathbf{x}(n-k) = z(n) \quad (1)$$

em que a_k são os coeficientes do modelo e $z(n)$ é um ruído branco com distribuição Gaussiana com média zero e variância σ^2 . De acordo com [21] a ordem que produzirá o menor erro é $p = 3$.

3 CONTROLE ATIVO DE VIBRAÇÃO

Para entender e controlar a vibração de uma estrutura, primeiro é necessário caracterizar suas propriedades vibracionais da estrutura, isso é, ter certo conhecimento de como as partes da estrutura vibram. A caracterização da vibração é essencial para antecipar os níveis de vibração ou determinar quais ações podem ser tomadas para controlar a vibração. Embora o controle passivo de ruído tenha sido o método predominante usado em aplicações de controle de tremores, a busca pelo controle final da vibração avançou na medida em que o uso de forças ativas seria preferível para neutralizar a vibração. Este método de controle de vibração é chamado de Controle Ativo de Vibração (*Active Vibration Control – AVC*), em que os coeficientes do controlador são atualizados constantemente por um algoritmo adaptativo.

O esquema de AVC, como destacado na Figura 1, consiste basicamente em sistema da planta¹, atuadores, sensores e controladores. Para os teste realizados são gerados dois sinais aleatórios brancos, Gaussianos com média zero e variância unitária e descorrelacionados. Na Figura 1 são representados pelos blocos Gerador de Ruído e $x(n)$. O sinal $x(n)$ é utilizado para fazer o reconhecimento dos coeficientes da planta da malha principal (caminho direto) $W(z)$, por outro lado, o gerador de ruído é um anti-sinal gerado na malha (ou caminho) secundária(o) para o reconhecimento dos coeficientes do filtro $S(z)$. Para controlar o sinal de tremor fisiológico a planta de $S(z)$ deve ser um modelo proporcional a $P(z)$, neste trabalho usa-se $S(z) = 0, 1P(z)$. A resposta do sinal de entrada na malha

¹Coefficientes que caracterizam o comportamento do sistema dinâmico.

secundária em um filtro de resposta ao impulso finito FIR serve para filtrar o sinal de $x(n)$, que por sua vez alimenta o algoritmo adaptativo, que atua tanto para reconhecer e estimar os coeficientes da malha principal quanto para controlar o sinal de ruído através da malha secundária.

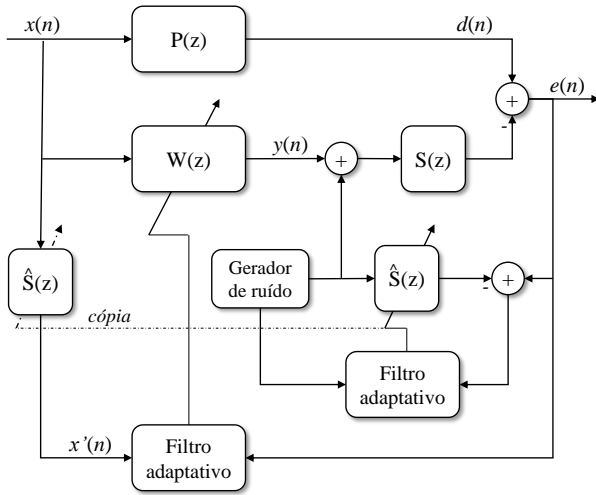


Figura 1: Diagrama em blocos do funcionamento básico de um sistema adaptativo de AVC.

O controle ativo de vibração baseado em filtros adaptativos de resposta ao impulso finito (FIR) normalmente introduz um atraso de dispersão de sinal condicional [22]. Os motivos para esses atrasos são arranjos geométricos e o tempo computacional em conversores analógicos-digitais (ADCs) e em conversores digitais-analógicos (DACs) usados. Os atrasos representam uma mudança de fase nos sinais periódicos. Esses atrasos evitam a *feedback* instantâneo dos sinais a partir do algoritmo *Least-Mean Square* (LMS), por exemplo. Isso pode levar a instabilidade e até divergência dos algoritmos. Estudos têm apresentado uma modificação do algoritmo LMS, ajustando o algoritmo de descida de gradiente subjacente [23–26] para contornar tal problema. O resultado é que todos os atrasos que ocorrem podem ser totalmente compensados.

Diferentes estratégias são propostas para o uso do algoritmo LMS no controle de ruído e de vibrações, normalmente levando em consideração que apenas o LMS não é capaz de atenuar sinais imprevisíveis como tremores fisiológicos, por exemplo. No controle ativo de vibração, devido à utilização de uma malha secundária, algoritmos tradicionais como LMS ou RLS (*Recursive Least-Square*), não devem ser aplicados. Porém a solução para este problema está na filtragem do sinal de entrada, usando uma estimativa da malha secundária. O *Filtered-x Least Mean Square* (FX-LMS) e suas variações, que serve de base para esta análise, foi uma alternativa proposta por Widrow et al. (1975) [27]. A estratégia adotada também em [18] utiliza o método controle de modelo interno (*Internal Model Control - IMC*²), juntamente com o algoritmo FX-LMS para suprimir ruídos

²Os sistemas de controle de modelo interno são caracterizados por um dispositivo de controle composto pelo controlador e por uma simulação do processo, o modelo interno.

e vibrações. Os seus resultados apresentam robustez e segmento de valores de referência.

Neste trabalho, serão avaliados alguns algoritmos adaptativos baseados no algoritmo dos mínimos quadrados médios para controle ativo de sistemas de vibração variável. A estrutura utiliza ainda um filtro auxiliar para melhorar a estimativa online do caminho secundário. O caminho secundário é representado pelas funções de transferência do filtro auxiliar e do controlador, e seu modelo de resposta ao impulso finito (FIR) é também estimado com uma estratégia adaptativa.

3.1 Algoritmo adaptativos

A definição de autômato adaptável, segundo Widrow (1995), consistem em um sistema que possua sua estrutura ajustável de tal forma que, baseando-se em um valor desejável, sua performance melhora de acordo com seu contato com o meio aplicado [28]. Assim, algoritmos adaptativos são empregados onde há uma constante mudança no seu meio. Normalmente são aplicados em sistemas de tempo real, sendo necessário uma relação mínima de cálculo por amostra. Esses algoritmos possuem um processo de medição a fim de chegar mais próximo ao valor desejado. Segundo Aslam et al. (2019) e Nascimento e Silva (2014), os filtros adaptativos podem ser vistos como um algoritmo desagregador da mistura de dois sinais e, para isso, os valores de referência de um dos sinais são essenciais [26, 29].

3.1.1 Algoritmo Least-Mean Square (LMS).

O algoritmo LMS (*Least Mean Square*) é um dos algoritmos de filtragem adaptativa mais comumente usado devido a sua simplicidade computacional, facilidade de provar sua eficiência em ambientes estacionários, comportamento estável quando implementado com precisão aritmética finita e por não necessitar estimar o gradiente de aproximação de valores de maneira *off-line* [28, 30]. O emprego de algoritmos de aprendizado adaptativo com inferência estatística permitem estimar o comportamento de sistemas que apresentam características que podem se modificar com o tempo, como é o caso de sinais provenientes de tremor nas mãos.




Figura 2: Diagrama de pesos do algoritmo LMS [27].

A Figura 2, mostra um diagrama que auxilia na compreensão do LMS. O vetor $\mathbf{x} = (x_0, x_1, \dots, x_n)$ representa os valores da entrada do sistema, o vetor $\mathbf{w} = (w_0, w_1, \dots, w_n)$ se refere aos pesos do algoritmo, os quais serão atualizados a cada iteração, $y(n)$ representa a saída estimada pelos pesos e a entrada, e é calculada por:

$$y(n) = \mathbf{x}^T(n) \mathbf{w}(n). \quad (2)$$

O sinal $d(n)$ é o sinal que deseja-se aproximar pela saída $y(n)$ do sistema e o $e(n)$ representa o valor do erro no instante n .

Assim, tem-se:

$$e(n) = d(n) - y(n) \quad (3)$$

e portanto,

$$e(n) = d(n) - \mathbf{x}^T(n) \mathbf{w}(n) \quad (4)$$

Elevando-se o valor do erro (4) ao quadrado a fim de minimizá-lo, obtém-se:

$$e^2(n) = d^2(n) - 2d(n) \mathbf{x}^T(n) \mathbf{w}(n) + \mathbf{x}(n) \mathbf{w}^T(n) \mathbf{w}(n) \mathbf{x}^T(n) \quad (5)$$

O erro quadrático médio (*Mean Square Error* – MSE) é obtido a partir do cálculo do operador média, $E[\cdot] = \xi(n)$, na Equação (5),

$$\xi(n) = E[d^2(n)] - 2E[d(n)\mathbf{x}^T(n)]\mathbf{w}(n) + \mathbf{w}^T(n)E[\mathbf{x}(n)\mathbf{x}^T(n)]\mathbf{w}(n) \quad (6)$$

ou ainda,

$$\xi(n) = E[d^2(n)] - 2\mathbf{p}_{xd}^T(n) \mathbf{w}(n) + \mathbf{w}^T(n) \mathbf{R}_{xx} \mathbf{w}(n) \quad (7)$$

em que $\mathbf{p}_{xd} = E[d(n)\mathbf{x}(n)]$ é vetor de correlação cruzada dos sinais de entrada e saída e $\mathbf{R}_{xx} = E[\mathbf{x}(n)\mathbf{x}^T(n)]$, conhecido como matriz de autocorrelação determinística do sinal de entrada.

Observa-se então, a partir da Equação (7), que o MSE é dado em função dos pesos, logo os pesos devem ser ajustados para reduzir o erro. Esse ajuste de pesos recai sobre um gradiente negativo na taxa de decaimento do erro médio quadrático com relação ao ajuste de pesos, como é mostrado na aplicação da derivada na Equação (6):

$$\frac{d\xi(n)}{d\mathbf{w}(n)} = -2d(n)\mathbf{x}(n) + 2\mathbf{x}(n)\mathbf{x}^T(n)\mathbf{w}(n) = \nabla(n) \quad (8)$$

$$\nabla(n) = -2\mathbf{x}(n)[d(n) - \mathbf{x}^T(n)\mathbf{w}(n)] \quad (9)$$

Substituindo a Equação (4) na Equação (9), tem-se:

$$-\nabla(n) = 2\mathbf{x}(n)e(n) \quad (10)$$

A matriz \mathbf{R}_{xx} é uma matriz definida positiva e a solução, \mathbf{w}_o , que minimiza o MSE normalmente conhecida como solução de Wiener dado por:

$$\mathbf{w}_o = \mathbf{R}^{-1}(n)\mathbf{p}(n). \quad (11)$$

A equação de atualização dos pesos do algoritmo LMS é dada por:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mu[-\nabla(n)]. \quad (12)$$

em que μ é o passo de adaptação do algoritmo, responsável pelo tamanho do ajuste no acréscimo, quanto menor este ajuste mais preciso a adaptação, porém um valor muito pequeno de μ pode acarretar em uma resposta mais lenta do sistema de adaptação devido ao número elevado de pontos. Substituindo-se os valores da Equação (10) na Equação (12), tem-se:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mu\mathbf{x}(n)e(n). \quad (13)$$

3.1.2 Algoritmo Normalized Least Mean Square (NLMS).

O algoritmo NLMS é uma variação do LMS convencional. No LMS o valor de passo de aprendizagem μ é um valor fixado, já no NLMS este valor é variável no tempo, na forma $\mu(n)$ [31].

Assim, no caso do NLMS pode-se escrever a Equação (13) da seguinte maneira:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mu(n)\mathbf{x}(n)e(n). \quad (14)$$

Sendo então necessário definir o erro posterior, já que o valor passo adaptativo é variável. Desse modo:

$$e_p = d(n) - \mathbf{w}^T(n+1) \mathbf{x}(n) \quad (15)$$

Substituindo a Equação (14) em (15), obtém-se:

$$e_p = [1 - \mathbf{x}^T(n)\mathbf{x}(n)\mu(n)]e(n) \quad (16)$$

O valor de $\mu(n)$, que aproxima o valor do erro ao seu mínimo, é dado por:

$$\mu(n) = \frac{1}{\|\mathbf{x}(n)\|^2} \quad (17)$$

Sendo $\frac{1}{\|\mathbf{x}(n)\|^2}$ obtido como mostra a Equação 18 :

$$\frac{1}{\|\mathbf{x}(n)\|^2} = \sum_{i=0}^{M-1} |\mathbf{x}(n-i)|^2 \quad (18)$$

Substituindo a Equação (17) na Equação (14), encontra-se:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \frac{1}{\|\mathbf{x}(n)\|^2} \mathbf{x}(n)e(n). \quad (19)$$

Porém, nesta pesquisa o valor de μ é fixado no numerador ponderado pela norma do sinal de entrada [32]. Esse fator de escala é importante para controlar a alteração no vetor de pesos de uma interação para a próxima sem alterar a direção do vetor. Sendo então a Equação (20), de atualização de pesos no NLMS, dada por:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \frac{\mu}{\|\mathbf{x}(n)\|^2} \mathbf{x}(n)e(n). \quad (20)$$

3.1.3 Algoritmo Fx-LMS. Para aplicações de controle ativo de ruído em tempo real o algoritmo LMS, devido ao longo *delay*, não é o algoritmo mais indicado, pois ruídos na entrada do sistema pode gerar instabilidade. Como alternativa a esse problema [27] apresentou como solução um algoritmo que possui uma entrada de sinal estimado, em que o sinal de referência é filtrado, de forma adaptativa e comparado com o sinal de entrada, obtendo-se o sinal estimado. O algoritmo Fx-LMS é normalmente utilizado para atualizar o filtro adaptativo, como mostra a Figura 3.




Figura 3: Diagrama em blocos do algoritmo Fx-LMS.

A análise da convergência do Fx-LMS com sinais estocásticos na entrada é apresentada em [33] considerando um processo de média móvel. Nesse caso, $P(z)$ é a planta do caminho primário e

$\widehat{\mathbf{S}}(z)$ representa o valor estimado de $\mathbf{S}(z)$, sua planta no caminho secundário. Assim, a estimativa de $\mathbf{S}(z)$ é dada por:

$$\widehat{\mathbf{S}}(z) = \sum_q^{Q-1} \frac{\mathbf{S}_q}{z^q}. \quad (21)$$

A equação que representa o erro, no domínio do tempo, para o sistema pode ser descrita como:

$$e(n) = d(n) - \sum_q^{Q-1} \mathbf{S}_q y(n-q). \quad (22)$$

Considerando a saída $y(n) = \mathbf{w}^\top(n)\mathbf{x}(n)$, como na Equação (4), substituindo em (22), obtém-se uma equação do erro:

$$e(n) = d(n) - \sum_q^{Q-1} \mathbf{S}_q \mathbf{x}^\top(n-q)\mathbf{w}(n-q). \quad (23)$$

Utilizando uma metodologia análoga a solução ótima de Wiener, obtém-se expressão similar à Equação (11), porém com valores filtrados, dada por:

$$\mathbf{w}_* = \mathbf{R}_f^{-1}(n)\mathbf{p}_f(n). \quad (24)$$

em que \mathbf{w}_* denota o vetor ótimo de pesos, $\mathbf{R}_f(n)$ denota a matriz de correlação das entradas filtradas e $\mathbf{p}_f(n)$ representa a relação cruzada entre a entrada filtrada e o sinal desejado.

A expressão para a entrada $\mathbf{x}_f(n)$ é obtida através da filtragem de $\mathbf{x}(n)$ em relação a $\widehat{\mathbf{S}}(n)$:

$$\mathbf{x}_f(n) = \sum_q^{Q-1} \mathbf{S}_q \mathbf{x}(n-q). \quad (25)$$

O valor ótimo do erro mensurado substituindo as Equações (24) e (25) em (23), é dado por:

$$e_*(n) = d(n) - \mathbf{w}_*^\top(n)\mathbf{x}_f(n). \quad (26)$$

A partir da Equação (26) o vetor de pesos que atualiza o algoritmo Fx-LMS é:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mu e(n)\mathbf{x}_f(n) \quad (27)$$

em que μ , assim como no LMS, é o passo de aprendizagem do algoritmo.

4 CONFIGURAÇÃO DAS SIMULAÇÕES

Nesta seção são apresentadas configurações de simulação para comparação de algoritmos adaptativos para controle de tremores em membros superiores. O Fx-LMS e suas variações, que servem de base para esta análise, foi uma alternativa para resolver o problema de algoritmos tradicionais como LMS e RLS [27].

O modelo utilizado para simular tremores fisiológicos neste trabalho baseia-se no estudo de Zhang and Chu (2005), em que os coeficientes dos pesos do modelo descrito por um processo AR, foram obtidos através da filtragem pelo algoritmo Levinson-Durbin³ [20]. A análise do algoritmo foi realizada pelo mínimo MSE, que apresentou um erro residual de 5×10^{-3} para um modelo de ordem 3.

Os coeficientes usados no modelo AR(3) para reproduzir o tremor fisiológico foram $\mathbf{w} = [-2.7288 \ 2.5774 \ 0.8342]$. Foi usado um sinal

Gaussiano branco, com média zero e variância unitária para produzir o sinal desejado $d(n)$ apresentado na Figura 1.

O passo de adaptação dos algoritmos analisados foi mantido para todos os algoritmos, assim como o número de interações. Após exaustivos testes, optou-se pelo uso de $\mu = 0,1$ na malha direta e $\mu = 0,01$ na malha secundária. Deste modo foram obtidos os melhores resultados para ambos algoritmos e cenários.

A partir dos resultados é possível fazer uma análise do comportamento dos algoritmos Fx-LMS e Fx-NLMS no controle de tremor fisiológico em uma malha que considera o ajuste online do caminho secundário, dispensando o período de calibração do equipamento. Além disso, considerando as características desses algoritmos avalia-se também o comportamento para uma abordagem híbrida, sendo intitulado Fx-NLMS&LMS, pois trata-se de uma sugestão de mudança do formato tradicional dos algoritmos acima citados.

5 RESULTADOS

Os resultados desta pesquisa serão apresentados pela comparação entre os algoritmos Fx-LMS, Fx-NLMS e LMS. No primeiro e segundo cenários os filtros adaptativos (Figura 1) foram atualizados utilizando o algoritmo Fx-LMS e Fx-NLMS, respectivamente. No terceiro cenário foi considerada uma condição híbrida, em que o filtro adaptativo correspondente ao caminho direto é atualizado pelo algoritmo Fx-LMS e o filtro no caminho secundário é atualizado pelo algoritmo Fx-NLMS. A diferença básica entre os três cenários está na normalização do sinal de erro das malhas principal e secundária. No Cenário 1, Fx-LMS, não há normalização dos dados do sinal de erro das malhas do algoritmo. No Cenário 2, Fx-NLMS, há normalização dos dados tanto na malha principal quanto na malha secundária. Já no Cenário 3, Fx-NLMS&LMS, a normalização é feita apenas na malha secundária.

5.1 Cenário 1

O comportamento do algoritmo Fx-LMS (Cenário 1) no controle ativo de vibração de tremor fisiológico é apresentado na Figura 4. O regime permanente é atingido após, aproximadamente, 5000 amostras.

A Figura 5, apresenta o resultado da intensidade do sinal de erro médio quadrático (MSE) normalizado, com um valor final médio de -22dB.

5.2 Cenário 2

O algoritmo Fx-NLMS possui dados normalizados tanto na malha principal quanto na malha secundária e seu resultado para controle do sinal de tremor fisiológico é ilustrado pela Figura 6. Neste caso, aproximadamente 4000 amostras são necessárias para que o sinal de controle convirja, seguindo os valores de referência, e seja suficiente para minimizar os tremores.

Já a Figura 7 mostra os resultados quando os dados do sinal de erro médio quadrático normalizado. Assim como no cenário 1, o erro quadrático, após convergência dos coeficientes atinge um valor médio de -22 dB de atenuação.

5.3 Cenário 3

No cenário 3, híbrido, a estrutura de controle utiliza os algoritmos Fx-NLMS&LMS, que possui dados normalizados no erro da

³Mais detalhes sobre essa abordagem podem ser encontradas em [34]

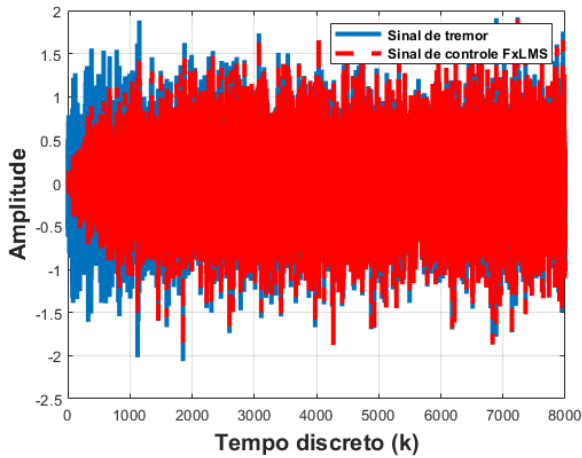


Figura 4: Avaliação do controle: em azul o sinal de tremor fisiológico em em vermelho o sinal de controle produzido pelo algoritmo Fx-LMS.

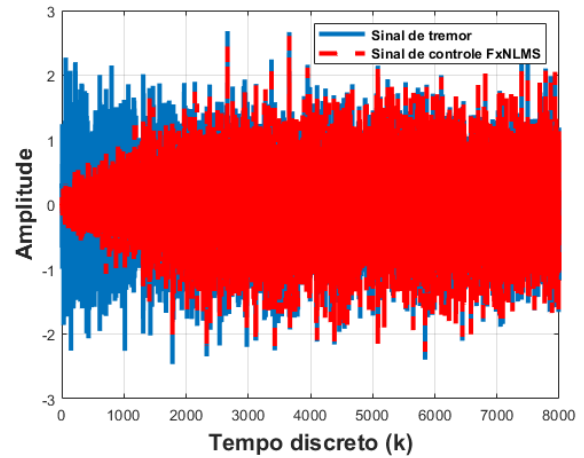


Figura 6: Avaliação do controle: em azul o sinal de tremor fisiológico em em vermelho o sinal de controle produzido pelo algoritmo Fx-NLMS.

Fonte: Autoria própria.

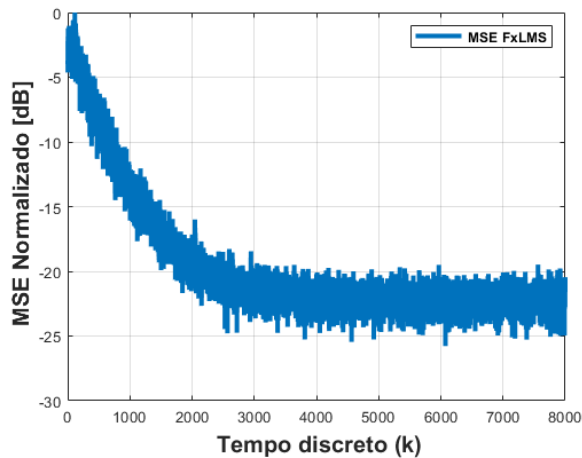


Figura 5: MSE normalizado para o algoritmo Fx-LMS para 100 realizações de uma simulação de Monte Carlo.

Fonte: Autoria própria.




Figura 7: MSE normalizado para o algoritmo Fx-NLMS para 100 realizações de uma simulação de Monte Carlo.

Fonte: Autoria própria.

malha secundária. Este arranjo de algoritmos é uma sugestão deste trabalho com relação a uma mudança na normalização apenas da malha interna. Desta forma, a Figura 8 evidencia o resultado de controle do algoritmo, onde o regime permanente é alcançado com aproximadamente 3000 amostras.

Com relação ao erro médio quadrático, o Fx-NLMS&LMS, conforme pode ser visto na Figura 9, obteve-se um valor inicial de, aproximadamente, -22 dB, assim como nos cenários 1 e 2.

5.4 Comparativo entre Fx-LMS, Fx-NLMS e Fx-NLMS&LMS

Os algoritmos Fx-LMS e Fx-NLMS, implementados nos cenários 1 e 2, respectivamente, apresentaram um nível de atenuação do erro quadrático médio semelhantes. A diferença de comportamento mais relevante se deu nos tempos de convergência de cada um deles. O algoritmo Fx-NLMS atingiu um erro de -22 dB em 4000 amostras, 1000 a menos do que o tempo obtido no cenário 1.




Figura 8: Avaliação do controle: em azul o sinal de tremor fisiológico em em vermelho o sinal de controle produzido pelo algoritmo Fx-NLMS-LMS.

Fonte: Autoria própria.

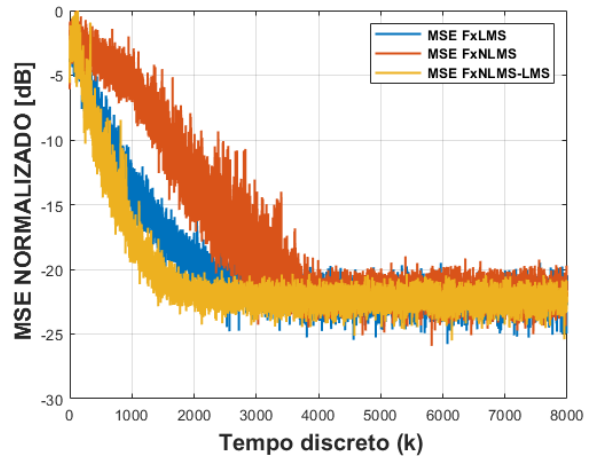


Figura 10: Comparativo do MSE normalizado dos algoritmos testados.

Fonte: Autoria própria.

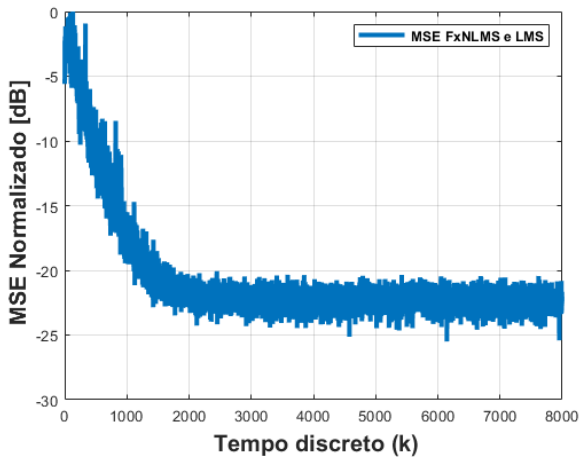


Figura 9: MSE normalizado para o algoritmo Fx-NLMS&LMS para 100 realizações de uma simulação de Monte Carlo.

Fonte: Autoria própria.

O algoritmo Fx-NLMS&LMS, implementado no cenário 3, mostrou-se mais rápido com relação aos outros algoritmos, sendo necessárias 3000 amostras para a realização do controle ativo, uma redução de 40% se comparado ao cenário 1. Este resultado pode ser atribuído a resposta rápida devido a filtragem de forma normalizada na modelagem da planta de $S(z)$. Esta comparação pode ser observada na Figura 10.

É claro que uma análise em termos da complexidade computacional adicionada a versão Fx-LMS é necessária para uma avaliação

do custo benefício. Mas, em um cenário em que não restrição de complexidade Fx-NLMS&LMS obteve convergência mais rápida.

A Tabela 2 apresenta de forma mais clara o comparativo final dos resultados do número de iterações e a amplitude da intensidade dos erros médios quadráticos.

Tabela 2: Tabela comparativa dos Resultados.

Algoritmo	Amostras	MSE
Fx-LMS	5000	-22 dB
Fx-NLMS	4000	-22 dB
Fx-NLMS-LMS	3000	-22 dB

Fonte: Autoria própria.

6 CONCLUSÕES

Algoritmos adaptativos normalmente possuem uma natureza complexa. Tendo em vista que há uma necessidade de um conhecimento de ferramentas da estatística, matemática, processamento de sinais e computação. Este trabalho buscou colaborar apresentando uma discussão sobre esses algoritmos e um sequência de ensaios científicos que permitisse sua aplicação em problemas de Engenharia Mecânica, Eletrônica, de Computação e Biomédica.

A revisão bibliográfica permitiu a construção e o levantamento dos conceitos necessários para aplicação das técnicas de filtragem adaptativa no objetivo de um controle ativo de vibração. Além disso, informações sobre o problema a ser solucionado e do conhecimento dos padrões vibratórios aqui citados. Essa busca se baseou em modelos matemáticos, evitando-se a necessidade da coleta de dados em pacientes de forma invasiva.

O Algoritmo Fx-NLMS&LMS apresentou melhor resposta dentre os algoritmos empregados nesta pesquisa. A sua diferença para

os demais, Fx-LMS e Fx-NLMS, está apenas no número de iterações. O algoritmo que obteve a resposta mais lenta resultado da não normalização na malha primária, onde é feito inicialmente o reconhecimento da planta do sistema. O algoritmo Fx-LMS é tradicionalmente empregado em AVC, podendo, de certa forma, servir como parâmetro em relação a suas variações, por hora empregados em controle de tremores fisiológicos.

Este estudo pode ser estendido para outros tipos de tremores, como os Parksonianos. Neste caso, algoritmos kernelizados podem produzir melhores resultados em sistemas com características não lineares presentes em modelos que replicam este tipo de patologia. Esses algoritmos tem sido aplicado pela comunidade científica e produzindo bons resultados

Além disso, uma implementação em dispositivos embarcados, placas DSP (*Digital Signal Processor*) podem melhorar o entendimento sobre o comportamento desses algoritmos em um cenário prático, que posteriormente serviriam como base para o desenvolvimento de um protótipo eletrônico com a tecnologia embarcada composta por um sensor e atuador para prover o controle ativo.

REFERÊNCIAS

- [1] OMS. Relatório mundial de envelhecimento. *USA: Organização Mundial de Saúde*, 2015.
- [2] V. L. Santos. Perfil epidemiológico da doença de parkinson no brasil. 2015.
- [3] L. J. Findley. Classification of tremors. *Journal of Clinical Neurophysiology*, 13(2): 122–132, 1996.
- [4] E. D. Louis and J. J. Ferreira. How common is the most common adult movement disorder? update on the worldwide prevalence of essential tremor. *Movement Disorders*, 25(5):534–541, 2010.
- [5] K. P. Bhatia, P. Bain, N. Bajaj, R. J. Elble, M. Hallett, E. D. Louis, J. Raethjen, M. Stamelou, C. M. Testa, G. Deuschl, et al. Consensus statement on the classification of tremors. from the task force on tremor of the international parkinson and movement disorder society. *Movement Disorders*, 33(1):75–87, 2018.
- [6] E. D. Louis and R. Ottman. Essential tremor. In *Genetics of Movement Disorders*, pages 353–363. Elsevier, 2003.
- [7] V. Carvalho and J. Massano. Tremor: Um guia clínico para não neurologistas. *Acta Medica Portuguesa*, 32(2), 2019.
- [8] V. Voon, T. C. Napier, M. J. Frank, V. Sgambato-Faure, A. A. Grace, M. Rodriguez-Oroz, J. Obeso, E. Bezard, and P-O. Fernagut. Impulse control disorders and levodopa-induced dyskinesias in parkinson's disease: an update. *The Lancet Neurology*, 16(3):238–250, 2017.
- [9] R. D. Sweet and F.H. McDowell. Five years' treatment of parkinson's disease with levodopa: therapeutic results and survival of 100 patients. *Annals of internal medicine*, 83(4):456–463, 1975.
- [10] H. Xiaowu, J. Xiufeng, Z. Xiaoping, H. Bin, W. Laixing, C. Yiqun, L. Jinchuan, J. Aiguo, and L. Jianmin. Risks of intracranial hemorrhage in patients with parkinson's disease receiving deep brain stimulation and ablation. *Parkinsonism & related disorders*, 16(2):96–100, 2010.
- [11] Paulo Henrique Fulanete Guiráo. Controle ativo de vibrações de rotores com mancais magnéticos: influência dos parâmetros do controlador pid. 2006.
- [12] Suhail Kazi, Musa Mailah, and Zarhamdy MD Zain. Suppression of hand postural tremor via active force control method. *Manufacturing Engineering, Automatic Control and Robotics*, 2014.
- [13] Pedro Angelo Medeiros Fonini. *Ambiente para testes em tempo real de filtros adaptativos para cancelamento de eco acústico*. PhD thesis, Universidade Federal do Rio de Janeiro, 2017.
- [14] A. Turkistani. Development of an effective portable and flexible glove for hand tremor suppression. 2017.
- [15] J. Chuanasa and S. Songschon. Essential tremor suppression by a novel self-balancing device. *Prosthetics and orthotics international*, 39(3):219–225, 2015.
- [16] S. Hosseini, A. Al-Jumaily, and S. A. Abboud. Active force control system for hand tremor suppression by different actuators. In *2016 5th International Conference on Electronic Devices, Systems and Applications (ICEDSA)*, pages 1–4. IEEE, 2016.
- [17] Anas Ibrahim, Yue Zhou, Mary E Jenkins, Ana Luisa Trejos, and Michael D Naish. Real-time voluntary motion prediction and parkinson's tremor reduction using deep neural networks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29:1413–1423, 2021.
- [18] Byeongil Kim and Jong-Yun Yoon. Modified lms strategies using internal model control for active noise and vibration control systems. *Applied Sciences*, 8(6): 1007, 2018.
- [19] Jacek Jakubowski, Krzysztof Kwiatos, Augustyn Chwaleba, and Stanislaw Osowski. Higher order statistics and neural network for tremor recognition. *IEEE Transactions on Biomedical Engineering*, 49(2):152–159, 2002.
- [20] Jing Zhang and Fang Chu. Real-time modeling and prediction of physiological hand tremor. In *Proceedings.(ICASSP'05). IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005.*, volume 5, pages v–645. IEEE, 2005.
- [21] George N Reeke, Roman R Poznanski, Kenneth A Lindsay, Jay R Rosenberg, and Olaf Sporns. *Modeling in the neurosciences: from biological systems to neuromimetic robotics*. CRC Press, 2005.
- [22] HS Dabis and TJ Moir. Least mean squares as a control system. *International Journal of Control*, 54(2):321–335, 1991.
- [23] Stephen Elliott, IANM Stothers, and Philip Nelson. A multiple error lms algorithm and its application to the active control of sound and vibration. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 35(10):1423–1434, 1987.
- [24] Pucha Song and Haiquan Zhao. Filtered-x least mean square/fourth (fxlms/f) algorithm for active noise control. *Mechanical Systems and Signal Processing*, 120:69–82, 2019.
- [25] Radek Martinek, Jaroslav Rzidky, Rene Jaros, Petr Bilik, and Martina Ladrova. Least mean squares and recursive least squares algorithms for total harmonic distortion reduction using shunt active power filter control. *Energies*, 12(8):1545, 2019.
- [26] Muhammad Saeed Aslam, Peng Shi, and Cheng-Chew Lim. Robust active noise control design by optimal weighted least squares approach. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2019.
- [27] Bernard Widrow, John R Glover, John M McCool, John Kaunitz, Charles S Williams, Robert H Hearn, James R Zeidler, JR Eugene Dong, and Robert C Goodlin. Adaptive noise cancelling: Principles and applications. *Proceedings of the IEEE*, 63(12):1692–1716, 1975.
- [28] Bernard Widrow and Samuel D Stearns. Adaptive signal processing prentice-hall. *Englewood Cliffs, NJ*, 1985.
- [29] Vitor H Nascimento and Magno TM Silva. Adaptive filters. In *Academic Press Library in Signal Processing*, volume 1, pages 619–761. Elsevier, 2014.
- [30] SR Diniz Paulo. *Adaptive filtering: algorithms and practical implementation*. Springer US, 2013.
- [31] Alexander D Poularikas. *Adaptive filtering: Fundamentals of least mean squares with MATLAB®*. CRC Press, 2017.
- [32] Ali H Sayed. *Fundamentals of adaptive filtering*. John Wiley & Sons, 2003.
- [33] I Tabatabaei Ardekani and Waleed H Abdulla. Theoretical convergence analysis of fxlms algorithm. *Signal Processing*, 90(12):3046–3055, 2010.
- [34] PJ Brockwell and Rainer Dahlhaus. Generalized levinson–durbin and burg algorithms. *Journal of Econometrics*, 118(1-2):129–149, 2004.