

Filtro de Kalman Modificado (FKM) para o Controle Ótimo de Tremores Parkinsonianos

Rafael Fatol Lopes*
rafael.fl1@puccampinas.edu.br
Pontifícia Universidade Católica de
Campinas – PUC-Campinas
Campinas, SP, Brasil

Vitor Yuzo Takei*
vitor.yt@puccampinas.edu.br
Pontifícia Universidade Católica de
Campinas – PUC Campinas
Campinas, SP, Brasil

Alexandre Fonseca Brandão
alexandre.brandao@puc-
campinas.edu.br
Pontifícia Universidade Católica de
Campinas – PUC Campinas
Campinas, SP, Brasil

Fábio Pires Itturriet
fabioitturriet@utfpr.edu.br
Universidade Tecnológica Federal do
Paraná – UTFPR
Curitiba, PR, Brasil

Renata Coelho Borges
renatacoelho@utfpr.edu.br
Universidade Tecnológica Federal do
Paraná – UTFPR
Curitiba, PR, Brasil

Wemerson Delcio Parreira
wemerson.delcio@puc-
campinas.edu.br
Pontifícia Universidade Católica de
Campinas – PUC-Campinas
Campinas, SP, Brasil

ABSTRACT

Parkinson's disease and other neurological disorders often manifest with involuntary tremors, significantly impacting quality of life. This study proposes the Modified Kalman Filter for tremor attenuation, proposing a novel modification to enhance its performance in hand vibration control. Despite the advancements in adaptive algorithms and deep learning models for tremor mitigation, challenges such as data acquisition and implementation in wearable devices persist. By leveraging the Kalman Filter's ability to estimate system states, we aim to develop a more effective and accessible solution for individuals with tremors. Our findings demonstrate that the Modified Kalman Filter can achieve significant tremor reduction, when compared to Kalman Filter, paving the way for future research in wearable assistive technologies and brain-computer interfaces.

KEYWORDS

Kalman, Non-Linear Systems, Parkinson, Control.

1 INTRODUÇÃO

A longevidade crescente está associada a um aumento na incidência de patologias relacionadas ao envelhecimento, como doenças neurológicas que causam tremores – movimentos oscilatórios involuntários em partes do corpo [1]. Esses tremores podem ser classificados em dois tipos principais: em ação, como o tremor essencial (ET), que afeta membros superiores e apresenta frequências de 4 Hz a 12 Hz; e em repouso, geralmente associado à doença de Parkinson (PD), com frequências de 3 Hz a 6 Hz. Ambos os tipos impactam a realização de tarefas cotidianas, como comer e escrever, dificultando significativamente a qualidade de vida [2, 3].

As abordagens convencionais para mitigar tremores incluem medicamentos, como a Levodopa, e intervenções cirúrgicas. No entanto, essas opções frequentemente acarretam efeitos colaterais ou limitações de aplicação [4]. Assim, dispositivos tecnológicos têm sido desenvolvidos para aplicar técnicas de controle ativo, passivo e semiativo de vibrações, como o uso de controladores proporcionais,

integrais e derivativos (PID) [5]. Por exemplo, estudos demonstram que o uso de atuadores piezoelétricos em modelos biomecânicos da mão humana podem suprimir tremores associados à PD de forma eficaz. Avanços em algoritmos adaptativos, tais como, *Least-Mean Square* (LMS), *Normalized Least-Mean Square* (NLMS), as versões filtradas FxLMS, FxNLMS, *Recursive Least Square* e Filtro de Kalman (KF), também têm contribuído para a melhoria de desempenho em sistemas de controle, possibilitando atualizações dinâmicas que aumentam a precisão e a eficiência [6–8].

Adicionalmente, modelos baseados em redes neurais profundas destacam-se pelo desempenho relevante em previsão e gestão de tremores em tempo real. Modelos como o 1D-CNN-MLP apresentaram taxas de redução de tremores acima de 90% [9]. Além disso, algoritmos adaptativos, como os baseados em controle por modelo interno (IMC) [10], têm sido propostos para gerenciar sinais multiespectrais, otimizando a estabilidade e a robustez do controle de vibrações. Essas soluções tecnológicas ampliam significativamente as possibilidades de intervenção, reduzindo atrasos e aumentando a precisão na mitigação de tremores. Porém, ainda com alta demanda de recursos computacionais, o que dificultaria a proposta de dispositivos embarcados com limitações de espaço, desempenho e energia tais como, caneta, canecas, talheres, etc.

Apesar dos avanços, desafios permanecem, como a dificuldade de coletar dados reais sobre tremores sem métodos invasivos e a necessidade de validar simulações computacionais em ambientes reais. Para contornar essas limitações, abordagens baseadas em modelos matemáticos e simulações estatísticas, como as realizadas com Monte Carlo, são utilizadas para analisar efeitos de atenuação e validar algoritmos de controle [6].

Assim, este trabalho apresenta uma versão modificada do filtro de Kalman (FK), denominada Filtro de Kalman Modificado (FKM) com o objetivo de aprimorar o mapeamento das não linearidades e melhorar o controle da vibração em dispositivos assistivos. Estudos futuros podem expandir essas soluções para dispositivos embarcados, integrando sensores e atuadores que promovam controle adaptativo em aplicações práticas, como luvas flexíveis ou sistemas de previsão de movimento assistido.

*Bolsista do Fundo de Apoio à Iniciação Científica – FAPIC/Reitoria PUC-Campinas.

2 MODELO MATEMÁTICO DE TREMORES NOS MEMBROS SUPERIORES

Neste trabalho, foi utilizado um modelo matemático de tremores das mãos que se assemelha aos padrões de sinais obtidos por meios clínicos e foi matematicamente validado. Dessa forma, nesta etapa, elimina-se a necessidade de adquirir sinais diretamente de seres humanos. Além disso, o uso de modelos matemáticos apresenta vantagens como fácil identificação, boa resolução espectral e uso conveniente em sistemas embarcados.

Teoricamente, o movimento parkinsoniano pode ser modelado por meio de uma análise de Fourier, utilizando sinais sinusoidais de múltiplas frequências, cujas amplitudes e fases são determinadas pelo espectro [11]. Dessa forma, o sinal de tremor, denotado por $\text{trm}(t)$, pode ser expresso por:

$$\text{trm}(t) = \text{sen}(f_1(t)) + \text{sen}(f_2(t)) + \text{sen}(f_3(t)) \text{sen}(f_4(t)) \quad (1)$$

em que $\{f_i(t)\}_{i=1,\dots,4}$ são funções reais definidas em diferentes frequências. Esse modelo se fundamenta em uma abordagem simples e é semelhante ao comportamento real de uma vibração produzida pelo pulso esquerdo de um paciente com Parkinson.

3 FILTRO DE KALMAN (FK)

O filtro de Kalman, descrito pela primeira vez em 1960 por Rudolf Emil Kalman [12], é amplamente utilizado em áreas como navegação autônoma e assistida. Esse filtro oferece uma solução recursiva para o problema de filtragem linear ótima em ambientes estacionários e não estacionários [13].

Segundo [14], as estimativas de estado são atualizadas com base na estimativa anterior e nos novos dados, evitando o cálculo a partir de todas as observações passadas a cada passo. Além disso, o filtro estima estados passados, presentes e futuros, mesmo quando a natureza do sistema é desconhecida.

Um sistema linear discreto pode ser descrito por [13]:

$$\hat{y}_n = Fy_{n-1} + Bu_{n-1} + c_{n-1}, \quad (2)$$

$$\hat{z}_n = Hny_n + v_n, \quad (3)$$

em que y é o estado do sistema, F é a matriz de transição de estado, B é a matriz de controle, c representa erros do sistema, v representa ruídos de medição, e H é a matriz de observação. As variáveis c e v são independentes e seguem distribuições normais, com covariâncias dadas por:

$$p(c) \sim N(0, Q), \quad (4)$$

$$p(v) \sim N(0, R) \quad (5)$$

em que Q é a matriz de covariância do ruído do processo, e R é a matriz de covariância do ruído de medição.

O FK possui duas etapas principais: predição e correção. Na predição, calcula-se a estimativa do estado e a propagação da covariância:

$$\hat{y}_n^- = F_{n,n-1} \hat{y}_{n-1}^-, \quad (6)$$

$$P_n^- = F_{n,n-1} P_{n-1} F_{n,n-1}^T + Q_{n-1}. \quad (7)$$

Na etapa de correção, calcula-se o ganho de Kalman:

$$k_n = P_n^- H_n^T [H_n P_n^- H_n^T + R_n]^{-1}, \quad (8)$$

e atualiza-se a estimativa de estado e a covariância:

$$\hat{y}_n = \hat{y}_n^- + k_n (x_n - H_n \hat{y}_n^-), \quad (9)$$

$$P_n = (I - k_n H_n) P_n^-. \quad (10)$$

O ganho de Kalman k_n define o peso dos dados medidos na atualização do estado. x_n é a medição no instante n , e I é a matriz identidade.

4 FILTRO DE KALMAN MODIFICADO (FKM)

A modificação de filtros lineares para incorporar métodos que lidem com não linearidades em sistemas biomédicos é essencial, especialmente em contextos como o processamento de sinais onde os comportamentos não lineares são frequentes [15]. Nesta modificação realiza-se uma transformação do espaço de entrada, semelhante a apresentada em [6].

O sinal de entrada u_{n-1} é modificado pela transformação não linear senoidal para $\text{sen}(\cdot)$ assim, a entrada do sistema será definida por:

$$\kappa_n = \text{sen}(2\pi u_n). \quad (11)$$

Aplicando (11) em (2) tem-se:

$$\hat{y}_n = Fy_{n-1} + B\kappa_{n-1} + c_{n-1}. \quad (12)$$

Com essa modificação pretende-se melhorar a precisão do FK para o controle de tremor de Parkinson, pelo impacto na atualização das Eq. (6)–(10), promovendo uma maior generalização para ambientes reais.

5 RESULTADOS E DISCUSSÃO

Nesta seção são apresentadas configurações das simulações bem como os resultados obtidos para validar o FKM como uma alternativa para a atenuação do tremor de Parkinson a partir do seu controle ótimo.

5.1 Métrica para avaliação

Para avaliação da modificação proposta em cenário de atenuação de vibração de tremor de Parkinson foi usado o erro médio quadrático acumulado (CMSE) – essa é uma métrica amplamente utilizada para avaliar o desempenho de sistemas ou algoritmos adaptativos ao longo do tempo – o cálculo é definido pela soma do MSE ao longo das iterações realizadas, isto é, para L realizações de Monte Carlo tem-se CMSE da n -ésima iteração, é dada por:

$$\text{CMSE}(n) = \sum_{k=1}^n \text{MSE}(k) = \sum_{k=1}^n \left(\frac{1}{L} \sum_{\ell=1}^L e^2(\ell, k) \right) \quad (13)$$

em que $e(\ell, k)$ representa o erro na k -ésima iteração da ℓ -ésima realização de Monte Carlo. Esta métrica oferece uma visão global do desempenho, sendo útil para avaliar a estabilidade, a precisão e a eficácia de algoritmos em minimizar erros ao longo do tempo, além de permitir comparações entre diferentes métodos ou configurações. Devido a sua natureza acumulativa as flutuações apresentadas no comportamento do MSE são omitidas.

5.2 Simulação

Para validar o algoritmo do FKM proposto é usado um modelo matemático apresentado na Seção 2 com as especificações apresentadas nesta seção.

O modelo do tremor Parkinsoniano foi construído utilizando uma combinação de duas senoides de frequências distintas – $f_1 = 5, 2 \text{ Hz}$,

$f_2 = 4,6 \text{ Hz}$, $f_3 = 4,9 \text{ Hz}$ e $f_4 = 0,35 \text{ Hz}$ — isto é,

$$\text{trm}(t) = \sin(2\pi f_1 t) + \sin(2\pi f_2 t) + \sin(2\pi f_3 t) \sin(2\pi f_4 t). \quad (14)$$

Usando (14), o sinal que simula o tremor Parkinson nas mãos é dado por:

$$sp_k = \text{trm}_k u_k \quad (15)$$

em que $u(\cdot)$ é um sinal com distribuição Gaussiana, média zero e variância unitária.

Adicionalmente, para simular os dados de um acelerômetro foi gerado um sinal independente, com distribuição Gaussiana, média zero e variância unitária z_k . Assim, o sinal que será controlado é definido por:

$$s_n = sp_k + z_k. \quad (16)$$

Neste processo foram usados $\sigma_Q^2 = \sigma_R^2 = 0,25$ nas matrizes de covariância do ruído do processo Q e R .

As Figuras 1 e 2 apresentam os resultados do comportamento, respectivamente, dos FKs e FKM. Nessas figuras, é possível observar que o sinal de controle estimado por ambos os algoritmos mantém amplitudes consistentes ao longo dos 5 s de observação, o que valida a capacidade de rastreamento da solução e demonstra a eficácia no controle e atenuação do tremor.




Figura 1: Comportamento do sinal de tremor e sinal controlado estimado por Kalman.




Figura 2: Comportamento do sinal de tremor e sinal controlado estimado por Kalman modificado.

Uma sutil diferença de desempenho entre o FK e o FKM é visualmente apresentada nos gráficos das Figuras 1 e 2. Essa diferença no desempenho se torna mais proeminente através da análise do CMSE, gerado através de 20 realizações de Monte Carlo, de ambas abordagens presentes na Figura 3. É possível observar que o comportamento geral do FKM (curva em laranja) é superior ao algoritmo do FK (curva em azul). Isso se deve ao fato de que a modificação proposta foi suficiente para que o algoritmo pudesse mapear as não linearidades do sistema a ser controlado. Sua superioridade pode ser notada ao longo das 100 primeiras iterações exibidas. Pois, embora nas 10 primeiras iterações o desempenho de ambos esteja próximo ($\approx 5 \text{ dB}$), ao longo das demais iterações o MSE acumulado atinge uma diferença superior a 10 dB. Essa diferença mostra que o CMSE do FKM é aproximadamente 25% inferior ao CMSE do FK. O que pode impactar significativamente ao longo do uso de um sistema com o controle promovido pelo FKM.




Figura 3: CMSE: comparação entre as duas abordagens

6 CONSIDERAÇÕES FINAIS

Este trabalho apresentou uma versão modificada do filtro de Kalman (FKM) para controle e atenuação de tremores associados à doença de Parkinson. A modificação, baseada em transformações não lineares no espaço de entrada, mostrou-se superior ao modelo tradicional em sistemas não lineares. Os resultados preliminares demonstraram que o FKM obteve desempenho significativamente melhor, reduzindo o CMSE em 10 dB nas 100 primeiras iterações. Tanto o FK quanto o FKM foram eficazes no rastreamento e atenuação dos sinais, mas a abordagem modificada destacou-se em precisão. O avanço significado apresentado nesse estudo aponta o FKM como uma promissora técnica voltada para aplicações em dispositivos embarcados aplicados ao controle de tremores.

REFERÊNCIAS

- [1] World Health Organization (WHO) et al. *Mental health: neurological disorders*. 2016. www.who.int/news-room/questions-and-answers/item/mental-health-neurological-disorders, accessed 06/2023.
- [2] PAHWA, R. et al. An acute randomized controlled trial of noninvasive peripheral nerve stimulation in essential tremor. *Neuromodulation*, p. 537–545, 2019.
- [3] BORGES, V.; FERRAZ, H. B. Tremores. *Revista Neurociências*, v. 14, n. 1, p. 43–47, 2006.
- [4] NIH. *Tremor*. 2023. Disponível em: <<https://www.ninds.nih.gov/health-information/disorders/tremor>>. Acesso em: 25 fev. 2023.
- [5] KAZI, S.; MAILAH, M.; ZAIN, Z. Suppression of hand postural tremor via active force control method. *Manuf Eng Autom Control Robot*, v. 2023, n. 20, p. 129, 2014.
- [6] ARAÚJO, R. S. A. et al. Analysis of adaptive algorithms based on least mean square applied to hand tremor suppression control. *Applied Sciences*, MDPI, v. 13, n. 5, p. 3199, 2023.
- [7] TIRONI, J. C. et al. Atenuação do sinal de tremores nas mãos: uma análise comparativa de algoritmos adaptativos. *Anais do Computer on the Beach*, v. 15, p. 096–101, 2024.
- [8] INGLE, V.; KOGON, S.; MANOLAKIS, D. *Statistical and Adaptive Signal Processing*. [S.l.: s.n.], 2005.
- [9] IBRAHIM, A. et al. Real-time voluntary motion prediction and parkinson's tremor reduction using deep neural networks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 29, p. 1413–1423, 2021.
- [10] KIM, S.; PETRUNIN, I.; SHIN, H.-S. A review of kalman filter with artificial intelligence techniques. In: *2022 Integrated Communication, Navigation and Surveillance Conference (ICNS)*. [S.l.: s.n.], 2022. p. 1–12.
- [11] REEKE, G. N. et al. *Modeling in the neurosciences: from biological systems to neuromimetic robotics*. [S.l.]: CRC Press, 2005.
- [12] KALMAN, R. E. A New Approach to Linear Filtering and Prediction Problems. *Journal of Basic Engineering*, v. 82, n. 1, p. 35–45, 03 1960. ISSN 0021-9223.
- [13] WELCH, G.; BISHOP, G. *An Introduction to the Kalman Filter*. 2006. Disponível em: <https://www.cs.unc.edu/~welch/media/pdf/kalman_intro.pdf>. Acesso em: 03 abril 2023.
- [14] HAYKIN, S. *Kalman Filtering and Neural Networks*. [S.l.]: Wiley, 2004. (Adaptive and Cognitive Dynamic Systems: Signal Processing, Learning, Communications and Control). ISBN 9780471464211.
- [15] SANTOS, V. A. D. et al. Improving speaker recognition in environmental noise with adaptive filter. *IEEE Access*, IEEE, v. 10, p. 124523–124533, 2022.