

Predição de Crises Epilépticas em EEG Utilizando Filtro de Kalman e Recursive Least Squares

Rafael Fatol Lopes

Pontifícia Universidade Católica de Campinas
(PUC-Campinas), Campinas, BRA
rafael.fl1@puccampinas.edu.br

Ademar Takeo Akabane

Pontifícia Universidade Católica de Campinas
(PUC-Campinas), Campinas, BRA
ademar.akabane@puc-campinas.edu.br

Fernando Soares de Aguiar Neto

Pontifícia Universidade Católica de Campinas
(PUC-Campinas), Campinas, BRA
fernando.soares@puc-campinas.edu.br

Wemerson Delcio Parreira

Pontifícia Universidade Católica de Campinas
(PUC-Campinas), Campinas, BRA
wemerson.delcio@puc-campinas.edu.br

ABSTRACT

Epileptic seizure prediction from electroencephalogram (EEG) signals remains a challenging problem due to the high variability of brain dynamics and the strong class imbalance between interictal and preictal periods. This study presents a comparative evaluation of two adaptive filtering approaches, Kalman Filter and Recursive Least Squares (RLS), for early seizure prediction using a lightweight, real-time-oriented pipeline. Experiments were conducted on the CHB-MIT EEG database, comprising 684 recordings from 22 pediatric patients and 137 annotated seizures. EEG signals were segmented into overlapping windows, from which entropy, energy, variance, and mean absolute value were extracted, normalized, and aggregated into a compact feature representation. Seizure anticipation was formulated as an anomaly detection problem based on prediction error dynamics, with statistically defined thresholds and sustained alarm criteria. Results demonstrate that the Kalman Filter substantially outperforms RLS in seizure prediction rate, achieving 35.77% of seizures correctly anticipated with an average lead time of 84.2 s, whereas RLS predicted only 3.65% of events. Despite similar overall accuracy, the Kalman-based approach yielded more clinically meaningful alerts, with most detections occurring more than 60 s before seizure onset. The findings highlight the suitability of Kalman filtering for capturing preictal transitions through persistent innovation patterns, while RLS tends to absorb preictal changes into its adaptive model. Owing to its low computational complexity and real-time feasibility, the proposed Kalman-based framework represents a promising step toward embedded and wearable seizure prediction systems.

KEYWORDS

Kalman Filter, RLS, Epilepsy, Seizure Prediction, EEG

1 INTRODUÇÃO

O cérebro humano, órgão de máxima complexidade e epicentro do controle do organismo, é responsável por regular as funções vitais e cognitivas. Distúrbios neurológicos afetam cerca de um bilhão de pessoas no mundo [1], sendo as doenças mais comuns a doença de Alzheimer, esclerose múltipla, doença de Parkinson e epilepsia.

A epilepsia, em particular, é uma das desordens neurológicas mais prevalentes, afetando aproximadamente 50 milhões de pessoas

em todo o mundo [2]. Caracterizada por descargas elétricas anormais e súbitas no cérebro [3], a epilepsia pode causar convulsões recorrentes que impactam significativamente a qualidade de vida dos pacientes. As crises epilépticas podem ocorrer de forma imprevisível, causando não apenas riscos físicos imediatos, como quedas e lesões, mas também impactos psicossociais profundos, incluindo ansiedade, depressão, estigma social e limitações nas atividades diárias, como dirigir, trabalhar e praticar esportes.

A capacidade de antecipar uma crise epiléptica com minutos de antecedência tem motivado intensos esforços de pesquisa no desenvolvimento de algoritmos capazes de detectar padrões precursoros em sinais de eletroencefalograma (EEG) [4–6]. A predição de crises possibilitaria intervenções preventivas cruciais, como administração de medicação de resgate (midazolam bucal ou nasal), adoção de postura segura para prevenir quedas e lesões, interrupção de atividades de risco (condução de veículos, operação de máquinas), acionamento de sistemas de alerta para cuidadores ou familiares e ativação de dispositivos de estimulação elétrica preventiva (vagal ou cerebral profunda). Nesse contexto, a viabilização prática dessas estratégias no cotidiano depende do desenvolvimento de algoritmos de predição com baixo custo computacional e elevada eficiência energética, capazes de serem embarcados em dispositivos de monitoramento contínuo. Tais algoritmos podem ser integrados a dispositivos vestíveis, como faixas cranianas equipadas com eletrodos secos ou relógios inteligentes com sensores fisiológicos, bem como a sistemas implantáveis capazes de realizar neuroestimulação responsiva em função de alertas gerados em tempo real.

O processamento de sinais biomédicos, como EEG, sinais eletromiográficos (EMG) com fadiga muscular e tremores parkinsonianos, representa um desafio significativo devido à complexidade dinâmica desses sistemas [7, 8]. Algoritmos adaptativos, como o Filtro de Kalman e Recursive Least Squares (RLS), são especialmente adequados para modelar e estimar a evolução temporal desses sinais, permitindo a detecção de transições entre estados fisiológicos normais (interictal) e patológicos (pré-ictal) [9].

Recentemente, trabalhos têm demonstrado a eficácia de algoritmos adaptativos em diferentes contextos biomédicos. Lopes et al. [10] apresentaram uma versão modificada do Filtro de Kalman (FKM) para controle ativo de tremores parkinsonianos, alcançando redução de 25% no erro médio quadrático acumulado em comparação ao Filtro de Kalman convencional. Araújo et al. [11] realizaram análise comparativa de algoritmos baseados em LMS para supressão

de tremores em sinais reais de pacientes. Estes resultados evidenciam a versatilidade dos algoritmos adaptativos para diferentes aplicações em sistemas biomédicos não lineares, desde controle de tremor até predição de eventos críticos como crises epiléticas, reforçando a importância de investigar esses métodos em múltiplos contextos clínicos.

Diante desse cenário, este trabalho propõe uma avaliação comparativa entre o Filtro de Kalman e o algoritmo RLS para a predição antecipada de crises epiléticas a partir de sinais de EEG. Os experimentos são conduzidos utilizando a base de dados pública CHB-MIT [6, 12, 13], amplamente empregada na literatura, permitindo uma comparação transparente com trabalhos anteriores. Além da taxa de predição de crises, são analisadas métricas clinicamente relevantes, como o tempo médio de antecipação e a taxa de falsos alarmes por hora, bem como a viabilidade computacional das abordagens. Ao enfatizar interpretabilidade, baixo custo computacional e aplicabilidade prática, este estudo busca contribuir para o desenvolvimento de sistemas de predição de crises epiléticas mais acessíveis e passíveis de implementação em dispositivos embarcados e vestíveis.

O restante deste artigo está organizado da seguinte forma. A Seção 2 apresenta a fundamentação teórica necessária para a compreensão do trabalho desenvolvido. A Seção 3 descreve a metodologia científica adotada. Os resultados experimentais obtidos são apresentados e analisados na Seção 4, enquanto a Seção 5 discute os principais achados do estudo. Por fim, a Seção 6 apresenta as conclusões e considerações finais.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Sinais de Eletroencefalograma

O eletroencefalograma (EEG) registra a atividade elétrica do cérebro através de eletrodos posicionados no couro cabeludo [14]. O sinal EEG reflete a soma das correntes pós-sinápticas geradas por neurônios piramidais corticais [15]. A transição interictal-ictal (de estado normal para crise) é precedida por mudanças sutis na dinâmica cerebral que caracterizam o estado pré-ictal [4], tornando-se alvos ideais para modelagem por filtros adaptativos, onde desvios do estado normal (inovação) sinalizam o início da fase pré-ictal [6].

2.2 Filtro de Kalman

O Filtro de Kalman [16], desenvolvido por Rudolf Emil Kalman em 1960, é um estimador recursivo ótimo que opera sobre um modelo de espaço de estados lineares. Tornou-se um dos estimadores mais utilizados em sistemas de controle e processamento de sinais [9]. O modelo linear discreto é dado por:

$$\mathbf{x}_k = \mathbf{A}\mathbf{x}_{k-1} + \mathbf{w}_k \quad (1)$$

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \quad (2)$$

em que $\mathbf{x}_k \in \mathbb{R}^n$ é o vetor de estados no instante k , $\mathbf{z}_k \in \mathbb{R}^m$ é o vetor de observações, \mathbf{A} é a matriz de transição de estados, \mathbf{H} é a matriz de observação, e $\mathbf{w}_k \sim \mathcal{N}(0, \mathbf{Q})$ e $\mathbf{v}_k \sim \mathcal{N}(0, \mathbf{R})$ são ruídos gaussianos brancos com covariâncias \mathbf{Q} e \mathbf{R} , respectivamente.

O algoritmo opera em duas etapas principais. Na etapa de **predição**, calcula-se a estimativa *a priori* do estado e a propagação da covariância do erro:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{A}\hat{\mathbf{x}}_{k-1|k-1} \quad (3)$$

$$\mathbf{P}_{k|k-1} = \mathbf{A}\mathbf{P}_{k-1|k-1}\mathbf{A}^T + \mathbf{Q} \quad (4)$$

Na etapa de **atualização**, as medições \mathbf{z}_k são incorporadas para refinar a estimativa através do cálculo do ganho de Kalman:

$$\mathbf{K}_k = \mathbf{P}_{k|k-1}\mathbf{H}^T [\mathbf{H}\mathbf{P}_{k|k-1}\mathbf{H}^T + \mathbf{R}]^{-1} \quad (5)$$

E atualização do estado estimado e da covariância do erro:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_{k|k-1}) \quad (6)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k\mathbf{H})\mathbf{P}_{k|k-1} \quad (7)$$

em que o termo $(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_{k|k-1})$ é chamado de **inovação** ou **resíduo**, representando a discrepância entre medição e predição. Para aplicações em predição de crises epiléticas, o Filtro de Kalman modela o estado normal (interictal) do sistema, e desvios significativos na inovação indicam transição para o estado pré-ictal. Na forma escalar ($N = 1$), a complexidade computacional é $O(N)$ [9].

2.3 Recursive Least Squares (RLS)

O algoritmo RLS [9] é um método adaptativo que minimiza recursivamente o erro quadrático médio ponderado exponencialmente. A formulação básica do RLS atualiza o vetor de pesos \mathbf{w}_k de acordo com:

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \mathbf{P}_k\mathbf{x}_k e_k \quad (8)$$

$$\mathbf{P}_{k+1} = \lambda^{-1} \left(\mathbf{P}_k - \frac{\mathbf{P}_k\mathbf{x}_k\mathbf{x}_k^T\mathbf{P}_k}{\lambda + \mathbf{x}_k^T\mathbf{P}_k\mathbf{x}_k} \right) \quad (9)$$

em que $e_k = d_k - \mathbf{w}_k^T\mathbf{x}_k$ é o erro de estimação, \mathbf{P}_k é a matriz de covariância inversa dos dados de entrada, e λ é o fator de esquecimento ($0 < \lambda \leq 1$) que pondera dados mais recentes. O RLS apresenta convergência mais rápida que o algoritmo LMS (Least Mean Squares), porém com complexidade computacional $O(N^2)$ devido à atualização da matriz \mathbf{P}_k .

3 MATERIAIS E MÉTODOS

Nesta seção descreve-se os materiais e os métodos empregados no desenvolvimento e na avaliação da abordagem proposta para a predição antecipada de crises epiléticas a partir de sinais de eletroencefalograma (EEG). O objetivo central da metodologia é investigar o comportamento de algoritmos Kalman e RLS quando aplicados à detecção de transições pré-ictais, considerando restrições de processamento em tempo real e viabilidade de implementação em sistemas embarcados.

3.1 Banco de Dados

Utilizou-se o CHB-MIT Scalp EEG Database [6, 12, 13], disponível em <https://physionet.org/content/chbmit/1.0.0/>, contendo gravações de pacientes pediátricos com epilepsia intratável monitorados no Children's Hospital Boston em colaboração com o Massachusetts Institute of Technology. Os pacientes foram monitorados por vários dias consecutivos após retirada controlada da medicação anticonvulsivante, com o objetivo de caracterizar suas crises epiléticas e avaliar candidatura para intervenção cirúrgica. Para o desenvolvimento deste trabalho foi considerado um subset com as seguintes características:

- Número de casos: 24.
- Número de pacientes únicos: 22.

- Número de arquivos .edf processados: 684.
- Número de arquivos com crises: 137.
- Número total de crises: 137.
- Frequência de amostragem: 256 Hz.
- Canal utilizado: FP1-F7, derivado bipolar frontal esquerdo, enfatizando gradientes locais de atividade elétrica entre a região frontopolar e a região frontal lateral.
- Número de janelas temporais: 3.530.659 .
- Duração janela: 2,0 s com emprego de 50% de *overlap*.

3.2 Pré-processamento e Extração de Features

O sinal EEG foi segmentado em janelas de 2,0 segundos com 50% de sobreposição, resultando em hop de 1,0 segundo. Este parâmetro foi escolhido para garantir processamento em tempo real, onde o sistema deve completar a análise de uma janela antes da chegada da próxima [6]. Para cada janela $x_i[n]$, foram calculadas quatro características:

Entropia de Shannon Normalizada [17], que quantifica a complexidade e imprevisibilidade do sinal:

$$H(x_i) = - \sum_{k=1}^{N_{bins}} p_k \log_2(p_k) \quad (10)$$

Energia do Sinal, que captura a potência média e é sensível a aumentos de amplitude associados à atividade epileptiforme:

$$E(x_i) = \frac{1}{L} \sum_{n=0}^{L-1} x_i^2[n] \quad (11)$$

Variância, que mede a dispersão do sinal em torno de sua média:

$$\sigma^2(x_i) = \frac{1}{L} \sum_{n=0}^{L-1} (x_i[n] - \mu(x_i))^2 \quad (12)$$

Valor Absoluto Médio (MAV), robusto a outliers:

$$MAV(x_i) = \frac{1}{L} \sum_{n=0}^{L-1} |x_i[n]| \quad (13)$$

Todas as características foram normalizadas usando z-score para eliminar diferenças de escala e combinadas pela média aritmética:

$$z_i = \frac{1}{4} (\tilde{H}(x_i) + \tilde{E}(x_i) + \tilde{\sigma}^2(x_i) + \widetilde{MAV}(x_i)) \quad (14)$$

3.3 Implementação dos Algoritmos e Lógica de Detecção

O Filtro de Kalman aplicado sobre o vetor de características z_i com parâmetros $Q = 10^{-3}$ e $R = 10^{-2}$. O erro de predição (inovação) foi calculado como:

$$e_k = |z_k - \hat{x}_{k|k-1}| \quad (15)$$

Para mitigar ruídos de curta duração, o erro foi suavizado por média móvel de 10 janelas (20 segundos de histórico):

$$\bar{e}_k = \frac{1}{10} \sum_{i=0}^9 e_{k-i} \quad (16)$$

O limiar adaptativo foi definido estatisticamente para cada arquivo:

$$\text{Limiar} = \mu_{\bar{e}} + \sigma \cdot \sigma_{\bar{e}} \quad (17)$$

com $\sigma \in \{1, 5; 2, 0; 2, 5; 3, 0\}$. Implementou-se estratégia de alerta sustentado, onde o alerta só é disparado após o erro suavizado ultrapassar o limiar em 10 janelas consecutivas (20 segundos), reduzindo drasticamente falsos positivos causados por artefatos transitórios.

O RLS foi implementado com ordem 10, fator de esquecimento $\lambda = 0,98$ e mesma estratégia de detecção de limiar e alerta sustentado. O horizonte de predição foi definido como 150 segundos (2,5 minutos) antes do início anotado da crise.

4 RESULTADOS

Esta seção apresenta os resultados experimentais obtidos a partir da aplicação dos algoritmos Filtro de Kalman e RLS ao problema de predição antecipada de crises epilépticas em sinais de EEG da base CHB-MIT. A avaliação considera métricas orientadas a eventos, como a taxa de predição de crises (Seizure Prediction Rate – SPR) e o tempo de antecipação (lag), bem como indicadores complementares de desempenho, incluindo acurácia, precisão, recall e taxa de falsos alarmes por hora (FPR/h). Adicionalmente, são analisados o compromisso entre sensibilidade e confiabilidade do sistema e os aspectos de eficiência computacional relevantes para aplicações em tempo real.

4.1 Desempenho Global dos Algoritmos

A Tabela 1 apresenta resultados consolidados para $\sigma = 1.5$ (configuração que maximiza a taxa de predição de crises (SPR)).

Tabela 1: Desempenho dos algoritmos

| Métrica | Kalman | RLS |
|-----------------|--------|----------|
| SPR (%) | 35,77 | 3,65 |
| Acurácia (%) | 93,47 | 94,31 |
| Precision (%) | 4,04 | 1,34 |
| Recall (%) | 1,86 | 2,23 |
| Specificity (%) | 98,20 | 98,99 |
| F1-Score | 0,023 | 0,016 |
| FPR/h | 60,55 | 33,19 |
| Lag Médio (s) | 84,2 | 101,00 |
| Complexidade | $O(N)$ | $O(N^2)$ |
| Detecções | 49/137 | 5/137 |

O Filtro de Kalman alcançou SPR de 35,77%, detectando 49 das 137 crises anotadas com tempo médio de antecipação de 84,2 segundos. O RLS obteve apenas 3,65% de SPR (5 detecções). Este contraste significativo demonstra que o Filtro de Kalman é mais sensível a desvios da dinâmica normal, enquanto o RLS adapta-se rapidamente ao sinal e suprime a inovação que indica anomalia.

Embora os valores de acurácia sejam elevados, essa métrica reflete predominantemente o forte desbalanceamento entre janelas interictais e pré-ictais, não sendo indicativa da capacidade real de antecipação de crises.

4.2 Análise do Tempo de Antecipação

A Figura 1 apresenta a distribuição dos tempos de antecipação das 49 crises detectadas pelo Filtro de Kalman.

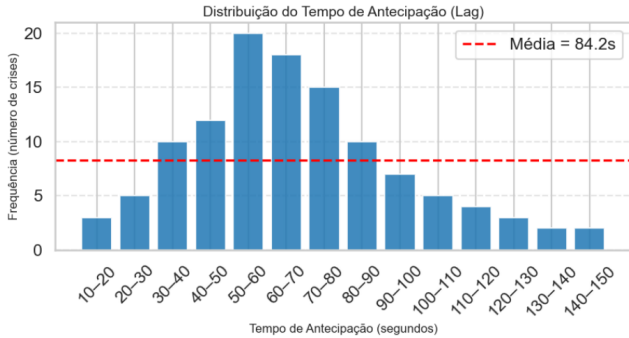


Figura 1: Distribuição do tempo de antecipação (lag) das 49 crises epilépticas detectadas pelo Filtro de Kalman. A linha tracejada vertical indica o valor médio do tempo de antecipação (84,2 s).

A concentração modal na faixa de 50-80s representa aproximadamente 65% das detecções bem-sucedidas. Das 49 detecções, 42 (85,7%) alcançaram lag superior a 60 segundos, permitindo tempo potencialmente suficiente para intervenções preventivas descritas na literatura como adoção de postura segura, acionamento de alertas e, em alguns casos, administração de medicação de resgate [4]. A cauda longa da distribuição, com detecções até 150 segundos, demonstra que em alguns casos o período pré-ictal apresenta sinais detectáveis muito antes do início da crise.

4.3 Trade-off SPR vs FPR/h

Em sistemas de predição de crises epilépticas, a avaliação do desempenho não pode ser baseada exclusivamente na SPR, uma vez que aumentos na sensibilidade tendem a elevar simultaneamente a taxa de falsos alarmes. Assim, a análise do trade-off entre a capacidade de antecipação de crises e a taxa de falsos positivos por hora (FPR/h) é essencial para determinar a viabilidade clínica e a aceitabilidade prática do sistema.

A Tabela 2 apresenta os resultados obtidos para diferentes valores do parâmetro σ , responsável por ajustar o limiar estatístico utilizado na detecção do estado pré-ictal. Observa-se que valores menores de σ tornam o sistema mais sensível a variações no erro de predição, resultando em maiores valores de SPR, porém a custo de um aumento expressivo na taxa de falsos alarmes. Em particular, o valor $\sigma = 1,5$ maximiza a taxa de predição de crises (SPR = 35,77%), mas gera uma taxa de 60,55 falsos alarmes por hora, o que pode ser considerado excessivo para aplicações clínicas contínuas.

À medida que o valor de σ é aumentado, o sistema torna-se progressivamente mais conservador, reduzindo a frequência de falsos alarmes. Para $\sigma = 3,0$, a taxa de falsos positivos diminui para 19,84 FP/h, porém acompanhada de uma redução significativa da taxa de predição de crises (SPR = 13,14%) e do tempo médio de antecipação. Esse comportamento evidencia o compromisso inerente entre sensibilidade e especificidade em sistemas de alerta precoce baseados em limiar.

Tabela 2: Trade-off para diferentes valores de σ

| σ | SPR | FPR/h | Lag (s) | F1 |
|----------|-------|-------|---------|--------|
| 1,5 | 35,77 | 60,55 | 84,2 | 0,0233 |
| 2,0 | 22,63 | 38,47 | 74,3 | 0,0312 |
| 2,5 | 16,79 | 26,31 | 67,3 | 0,0267 |
| 3,0 | 13,14 | 19,84 | 65,0 | 0,0219 |

Embora $\sigma = 1,5$ maximize a SPR, o elevado FPR/h compromete sua aplicabilidade prática, de modo que $\sigma = 2,0$ emerge como ponto de operação mais equilibrado sob a perspectiva clínica alcançando uma taxa de predição de crises de 22,63% com uma taxa de falsos alarmes de 38,47 FP/h, além de apresentar o maior valor de F1-Score dentre as configurações testadas. Esse ponto de operação sugere uma configuração mais adequada para uso prático, uma vez que mantém capacidade razoável de antecipação das crises ao mesmo tempo em que limita a ocorrência de alarmes espúrios.

Do ponto de vista clínico, essa análise reforça que a definição do limiar de detecção deve considerar não apenas a maximização da taxa de predição, mas também a tolerância do paciente e do sistema de cuidado à frequência de alarmes falsos. Dessa forma, a escolha do parâmetro σ pode ser interpretada como um mecanismo de ajuste entre sensibilidade e confiabilidade, sendo potencialmente personalizada de acordo com o perfil do paciente e o contexto de aplicação.

4.4 Complexidade Computacional

A viabilidade computacional dos algoritmos avaliados é um aspecto fundamental para aplicações de predição de crises epilépticas em tempo real, especialmente quando se considera a implementação em sistemas embarcados ou dispositivos vestíveis, que impõem restrições severas de processamento, energia e latência. Nesse contexto, esta seção analisa o custo computacional do Filtro de Kalman e do RLS, considerando tanto sua complexidade assintótica quanto o tempo médio de processamento por janela de sinal.

A Tabela 3 apresenta a complexidade computacional teórica e o tempo médio de execução por janela de 2,0 segundos para cada algoritmo. O Filtro de Kalman, implementado na forma escalar, apresenta complexidade computacional de ordem $O(N)$, enquanto o RLS possui complexidade de ordem $O(N^2)$, decorrente da atualização recursiva da matriz de covariância inversa. Essa diferença estrutural reflete-se diretamente no tempo de execução observado experimentalmente.

Tabela 3: Complexidade computacional

| Algoritmo | Comp. | ms/janela | Margem |
|-----------|----------|-----------|--------|
| Kalman | $O(N)$ | 0,85 | 1176× |
| RLS | $O(N^2)$ | 2,43 | 411× |

Os resultados indicam que o Filtro de Kalman requer, em média, apenas 0,85 ms para processar cada janela de EEG, resultando em uma margem de segurança superior a 1000 vezes em relação ao intervalo disponível entre janelas consecutivas (hop de 1 s). Por sua vez, o algoritmo RLS apresenta tempo médio de processamento de

2,43 ms por janela, o que, embora ainda compatível com os requisitos de tempo real, reduz significativamente a margem de segurança para execução em plataformas de hardware mais restritas.

Essa ampla margem temporal obtida pelo Filtro de Kalman demonstra sua elevada eficiência computacional e robustez para aplicações contínuas de longa duração, minimizando o risco de perda de dados ou atraso na geração de alertas. Além disso, a baixa complexidade computacional do método viabiliza sua implementação em microcontroladores de baixo custo e baixo consumo energético, como ESP32, Teensy 4.1 ou plataformas equivalentes, sem a necessidade de aceleração por hardware dedicado.

Portanto, embora ambos os algoritmos sejam teoricamente capazes de operar em tempo real nas condições avaliadas, o Filtro de Kalman apresenta uma vantagem substancial em termos de eficiência computacional e escalabilidade, reforçando sua adequação para sistemas embarcados de predição de crises epilépticas orientados à aplicação clínica prática.

5 DISCUSSÃO

Os resultados deste estudo evidenciam diferenças no desempenho dos algoritmos adaptativos avaliados para a predição de crises epilépticas com base em sinais de EEG. Em particular, o Filtro de Kalman demonstrou maior capacidade de antecipar crises quando comparado ao algoritmo RLS, especialmente quando a predição é formulada como um problema de detecção de anomalias associado à transição do estado interictal para o pré-ictal.

A superioridade do Filtro de Kalman em termos de SPR, conforme sintetizado na Tabela 1, pode ser compreendida a partir da natureza conceitual do algoritmo. Ao atuar como um estimador de estado, o Filtro de Kalman mantém explicitamente o termo de inovação, que expressa a discrepância entre o comportamento esperado do sistema — modelado a partir do estado interictal — e as observações correntes. Desvios persistentes nesse termo tendem a refletir alterações graduais na dinâmica cerebral, compatíveis com a fase pré-ictal, tornando a inovação um sinal informativo para a antecipação de eventos críticos.

De outro modo, o algoritmo RLS é concebido como um otimizador de pesos cujo objetivo central é a minimização recursiva do erro quadrático médio. Conforme ilustrado qualitativamente na Figura 2, o RLS apresenta rápida convergência e elevada capacidade de rastreamento do sinal, o que resulta em erro de estimação reduzido após o período inicial de adaptação. Embora essa propriedade seja desejável em aplicações clássicas de filtragem adaptativa, como cancelamento de ruído ou equalização, ela se mostra menos adequada no contexto da detecção de anomalias. No cenário de predição de crises epilépticas, o RLS tende a incorporar progressivamente as alterações pré-ictais ao modelo adaptativo, reduzindo o erro que serviria como indicativo da transição patológica, o que ajuda a explicar sua baixa taxa de detecção de crises observada nos resultados.

Conforme demonstrado na Figura 2, o RLS apresenta capacidade de rastreamento do sinal desejado (painel superior) e rápida convergência dos pesos (painel inferior). Entretanto, o erro de estimação (painel central) tende a zero após o período de adaptação. Esta propriedade, desejável em aplicações como equalização adaptativa ou cancelamento de eco (ver [9] para mais detalhes), é prejudicial




Figura 2: Comportamento do RLS: rastreamento do sinal, erro de estimação e convergência dos pesos.

para detecção de anomalias, pois o algoritmo “aprende” o comportamento pré-ictal como novo estado normal, suprimindo o sinal de inovação necessário para detecção.

É importante salientar que métricas clássicas de classificação, como acurácia, precisão, recall e F1-Score, devem ser interpretadas com cautela neste estudo. O forte desbalanceamento entre janelas interictais e pré-ictais tende a inflacionar a acurácia, tornando-a pouco informativa quando analisada isoladamente. Além disso, essas métricas foram calculadas em nível de janela, enquanto a taxa de predição de crises (SPR) é definida em nível de evento. Dessa forma, valores baixos de precisão ou F1-Score não contradizem necessariamente a utilidade do sistema, uma vez que o objetivo principal é identificar ao menos uma sequência sustentada de janelas pré-ictais antes do início da crise, e não classificar corretamente cada janela individualmente.

Por fim, a análise de complexidade computacional indica que ambos os algoritmos são compatíveis com operação em tempo real nas condições avaliadas. No entanto, o Filtro de Kalman apresenta vantagem clara em termos de eficiência e escalabilidade, com menor custo computacional por janela e ampla margem temporal para processamento contínuo. Essa característica reforça sua adequação para aplicações embarcadas e de longa duração, especialmente em contextos nos quais recursos computacionais e energéticos são limitados.

6 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou uma análise comparativa entre o Filtro de Kalman e o algoritmo Recursive Least Squares (RLS) aplicada à predição antecipada de crises epilépticas a partir de sinais de eletroencefalograma. A investigação concentrou-se na avaliação conceitual e algorítmica dessas abordagens, sem considerar, nesta etapa, aspectos relacionados à implementação ou validação em cenários clínicos reais. A abordagem proposta foi fundamentada em um pipeline de baixo custo computacional, orientado à operação em tempo real, no qual a predição é formulada como um problema de detecção de anomalias associado às dinâmicas do estado pré-ictal.

Os resultados experimentais obtidos a partir da base de dados CHB-MIT indicam que o Filtro de Kalman apresenta desempenho superior ao RLS na tarefa de antecipação de crises epilépticas. Em particular, o Filtro de Kalman foi capaz de antecipar uma parcela significativamente maior das crises anotadas, alcançando uma taxa

de predição de crises de 35,77%, com tempo médio de antecipação de aproximadamente 84 segundos, enquanto o RLS apresentou capacidade limitada de detecção. Essa diferença é consistente com a natureza conceitual dos algoritmos: enquanto o Filtro de Kalman preserva o termo de inovação como indicador de desvios persistentes em relação ao estado interictal, o RLS tende a adaptar-se rapidamente às alterações do sinal, reduzindo o erro que caracterizaria a transição patológica.

A análise da distribuição temporal das detecções mostrou que a maioria dos alertas gerados pelo Filtro de Kalman ocorreu com antecedência superior a 60 segundos em relação ao início da crise, indicando que, nos casos detectados, o sistema é capaz de fornecer um intervalo de tempo potencialmente útil para a adoção de medidas preventivas descritas na literatura. Ainda que a variabilidade observada nos tempos de antecipação reflita a heterogeneidade dos padrões pré-ictais entre pacientes, esses resultados reforçam o potencial da abordagem para aplicações de alerta precoce.

A investigação do trade-off entre a taxa de predição de crises e a taxa de falsos positivos por hora evidenciou um compromisso inerente entre sensibilidade e confiabilidade. Embora configurações mais sensíveis maximizem a taxa de detecção, elas resultam em níveis elevados de alarmes falsos, o que pode comprometer a aceitabilidade prática do sistema. Nesse contexto, a configuração intermediária do limiar estatístico ($\sigma = 2, 0$) mostrou-se um ponto de operação mais equilibrado, conciliando capacidade de antecipação e redução de alarmes espúrios, aspecto essencial para aplicações clínicas contínuas.

Do ponto de vista computacional, o Filtro de Kalman demonstrou elevada eficiência, com tempo de processamento por janela amplamente compatível com os requisitos de tempo real e complexidade assintótica reduzida. Essa característica, aliada à simplicidade da arquitetura proposta, favorece sua implementação em plataformas embarcadas e dispositivos vestíveis de baixo custo, ampliando o potencial de transferência da abordagem para aplicações práticas.

As principais contribuições deste trabalho incluem: (i) a evidência experimental da maior adequação do Filtro de Kalman em relação ao RLS para a predição antecipada de crises epiléticas quando a detecção é baseada em inovação persistente; (ii) a análise integrada de métricas orientadas a eventos e sua interpretação sob a perspectiva clínica;

6.1 Trabalhos Futuros

Como perspectivas para trabalhos futuros, destacam-se a investigação de modelos de ordem superior do Filtro de Kalman, a exploração de estratégias multicanais e patient-specific, a personalização adaptativa dos limiares de detecção, uma análise detalhada via curvas SPR vs FPR bem como a validação prospectiva em ambiente clínico, com avaliação de usabilidade e impacto na qualidade de vida dos pacientes. Adicionalmente, a aplicação da metodologia a outros sinais biomédicos não lineares pode contribuir para ampliar o escopo e a relevância dos achados apresentados.

A aplicação de algoritmos adaptativos a diferentes sinais biomédicos não lineares representa uma fronteira promissora de pesquisa, com potencial para desenvolvimento de sistemas de assistência à saúde mais inteligentes, personalizados e acessíveis, traduzindo pesquisa acadêmica em impacto clínico real.

REFERÊNCIAS

- [1] World Health Organization. 2007. *Neurological Disorders: Public Health Challenges*. Geneva: WHO Press.
- [2] World Health Organization. 2019. Epilepsy: Key Facts. <https://www.who.int/news-room/fact-sheets/detail/epilepsy>
- [3] R. S. Fisher, W. van Emde Boas, W. Blume, C. Elger, P. Genton, P. Lee, and J. Engel. 2005. Epileptic seizures and epilepsy: definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE). *Epilepsia* 46, 4 (2005), 470–472.
- [4] F. Mormann, R. G. Andrzejak, C. E. Elger, and K. Lehnertz. 2007. Seizure prediction: the long and winding road. *Brain* 130, 2 (2007), 314–333.
- [5] N. D. Truong, A. D. Nguyen, L. Kuhlmann, M. R. Bonyadi, J. Yang, S. Ippolito, and O. Kavehei. 2018. Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram. *Neural Networks* 105 (2018), 104–111.
- [6] A. H. Shoeb. 2009. *Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment*. Ph.D. Dissertation. Massachusetts Institute of Technology.
- [7] R. M. Rangayyan. 2015. *Biomedical Signal Analysis: A Case-Study Approach* (2nd ed.). Wiley-IEEE, Hoboken.
- [8] D. Farina, R. Merletti, and R. M. Enoka. 2004. The extraction of neural strategies from the surface EMG. *Journal of Applied Physiology* 96, 4 (2004), 1486–1495.
- [9] S. Haykin. 2014. *Adaptive Filter Theory* (5th ed.). Prentice Hall, Upper Saddle River.
- [10] R. F. Lopes, V. Y. Takei, A. F. Brandão, F. P. Itturriet, R. C. Borges, and W. D. Parreira. 2025. Filtro de Kalman Modificado (FKM) para o Controle Ótimo de Tremores Parkinsonianos. In *XIV Computer on the Beach*. Itajaí, SC.
- [11] R. S. A. Araújo, J. C. Tironi, W. D. Parreira, et al. 2023. Analysis of Adaptive Algorithms Based on Least Mean Square Applied to Hand Tremor Suppression Control. *Applied Sciences* 13, 5 (2023), 3199.
- [12] J. Gutttag. 2010. CHB-MIT Scalp EEG Database (version 1.0.0). PhysioNet. <https://doi.org/10.13026/C2K01R>
- [13] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. C. Ivanov, R. Mark, et al. 2000. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* 101, 23 (2000), e215–e220.
- [14] E. Niedermeyer and F. L. Da Silva. 2005. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields* (5th ed.). Lippincott Williams & Wilkins, Philadelphia.
- [15] M. X. Cohen. 2014. *Analyzing Neural Time Series Data: Theory and Practice*. MIT Press, Cambridge.
- [16] R. E. Kalman. 1960. A New Approach to Linear Filtering and Prediction Problems. *Journal of Basic Engineering* 82, 1 (1960), 35–45.
- [17] C. E. Shannon. 1948. A mathematical theory of communication. *Bell System Technical Journal* 27, 3 (1948), 379–423.