

Pré-Processamento de Dados de Imagem Funcional por Ressonância Magnética Usando o Filtro de Kalman

Valcir J. da C. Farias, Marcus P. C. da Rocha, Heliton R. Tavares

Programa de Pós-graduação em Matemática e Estatística-ICEN-UFPA

Rua Augusto Corrêa, 01, Belém, Pará

E-mail: valcir@ufpa.br; mrocha@ufpa.br; heliton@globo.com

Alessandra L. de Oliveira

Programa de Pós-graduação em Economia-ICSA-UFPA

Rua Augusto Corrêa, 01, Belém, Pará

E-mail: alima485@gmail.com

Resumo- Foi aplicado do filtro de Kalman no pré-processamento de imagens por ressonância magnética funcional-fMRI. Para testar o desempenho do filtro foram realizadas simulações numéricas da resposta hemodinâmica acrescida de ruído gaussiano. Utilizou-se como ferramenta de comparação o mapa auto-organizáveis. Os resultados da aplicação do filtro de Kalman, para dados simulados, revelou que ele pode ser usado como ferramenta na etapa de filtragem temporal em dados de fMRI.

1 INTRODUÇÃO

Das diversas técnicas interessadas em avaliar a função cerebral através de imagens, a mais empregada é a técnica de aquisição de imagens funcionais por ressonância magnética (fMRI)[3]. Esta técnica baseia-se no fenômeno da ressonância nuclear. A FMRI analisa a variação hemodinâmica e tem o diferencial de não submeter o voluntário a efeitos nocivos.

Em um experimento de ressonância magnética funcional, o sujeito permanece dentro de um equipamento de ressonância sendo submetido a estímulos variados. A atividade neural aos estímulos causa um aumento do fluxo sanguíneo e oxigenação nos vasos locais. O mecanismo de contraste BOLD, é a resposta da aplicação do protocolo experimental composto de mudanças periódicas entre estímulo e não-estímulo.

A evolução temporal do efeito BOLD é uma série temporal correspondente para cada voxel. A aquisição do sinal é feito em vários ciclos de repouso e estímulo fazendo com que o sinal de interesse seja próximo a uma onda quadrada de período constante.

O efeito BOLD dá origem a mudança de intensidade restrita a uma certa área do cérebro e transitórios no tempo em relação ao estímulo. No entanto, os efeitos são pequenos e corrompidos por ruído e artefatos. Um dos aspectos mais desafiantes da fMRI é encontrar métodos mais sensíveis de detecção e eliminação de ruído em meio ao sinal, pois a técnica é suscetível a várias fontes de ruído, causando nos dados do experimentos imprecisões temporais e espaciais.

Dentre as fontes que causam essas imprecisões, podemos citar o ruído devido ao movimento da cabeça de forma involuntária, ou causado por batimentos cardíaco, a respiração ou por outros processos fisiológicos, como por exemplo, diferenças no tempo de aquisição das imagens, ruído devido a imperfeições do hardware e ruído causado pela interferência de outros estímulos não relacionados à tarefa de interesse.

As séries temporais em um experimento de fMRI geralmente apresentam uma baixa relação sinal ruído, *Signal to Noise Ratio* (SNR). Desse modo, torna-se necessário algum tipo de pré-processamento para a filtragem do ruído presente no sinal. O ponto principal da filtragem temporal é remover componentes indesejáveis da série temporal sendo importante manter na filtragem a forma do sinal original.

As técnicas de pré- processamentos servem para diminuir a maioria dos ruídos citados, pois o ruído é uma componente indesejável e com variabilidade irrelevante presente no sinal associado à resposta BOLD. Se não houver as etapas de pré-processamento, a variabilidade pode invalidar o poder de detecção de áreas cerebrais consideradas ativas ou inativas em um experimento.

Neste artigo foi aplicado o Filtro de Kalman [4,5,7] para realizar o pré-processamento em dados de FMRI. Esse método é adaptado para filtrar sinais periódicos de modo a preservar a amplitude e a morfologia do sinal original. Para testar a eficiência do filtro de Kalman foi utilizado o mapa auto-organizável de Kohonen[1,2, 6]

2 APLICAÇÃO DO FILTRO DE KALMAN À FMRI

Será aplicada a equação diferencial que representa a estimativa do estado do filtro de Kalman na forma escalar:

$$\frac{d\hat{x}(t)}{dt} = -\sqrt{\gamma} \tanh(\sqrt{\gamma}t)\hat{x}(t) + \sqrt{\gamma} \tanh(\sqrt{\gamma}t)z(t) \quad (1)$$

O filtro de Kalman opera nas séries temporais dos voxels, $z(t)$, de forma separada, uma série de cada vez. A aplicação do filtro de Kalman nas séries temporais ocorre em janelas sequenciais definidas pelos ciclos de repouso e estímulo.

Baseando-se nas considerações teóricas do método de Kalman, desenvolve-se um algoritmo computacional para a aplicação do filtro, de forma que o parâmetro γ determina a qualidade do filtro. Considerou-se o parâmetro γ constante em todos os intervalos das janelas.

2.1 Modelo Sintético

Para comparar diferentes valores do parâmetro γ , são geradas séries temporais artificiais de voxels considerados ativos. Usando um sinal artificial, é possível comparar o sinal original, sinal ruidoso e sinal filtrado, determinando o fator de redução de ruído. Uma série temporal de um voxel verdadeiro não pode ser utilizada para esta tarefa, pois nenhum sinal de fMRI verdadeiro está completamente isento de ruído.

Nas séries temporais dos voxels foi adicionado ruído caracterizado por um padrão gaussiano. Os valores do desvio-padrão do ruído determinam as características da relação sinal ruído (SNR), medida em decibel (dB).

Usou-se o fator de redução de ruído, δ , como métrica de desempenho dada por:

$$\delta = \sqrt{\frac{\sum_k [z(k) - x(k)]^2}{\sum_k [\hat{x}(k) - x(k)]^2}}, \quad (2)$$

Onde, $x(k)$ é o sinal original sem ruído, $z(k)$ é o sinal com ruído e $\hat{x}(k)$ é o sinal filtrado, k é o índice da amostra.

Foram gerados artificialmente conjuntos de dados, de 64x64 voxels com 128 amostras no tempo, visto na Figura 1 com séries temporais simulando o sinal BOLD. O experimento consistiu de um paradigma em bloco. Foi considerado um SNR igual a -5dB.

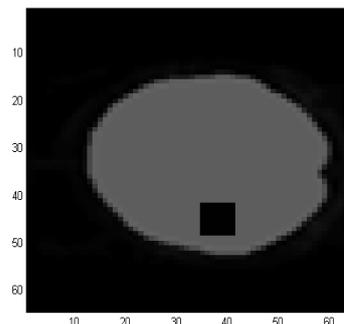


Figura 1- Imagem da fatia simulada: a área retangular interna representa uma região considerada ativa.

3 RESULTADOS

Para as séries temporais simuladas, diferentes resultados são apresentados quando há variação do parâmetro γ , que determina a qualidade do filtro. A Figura 2 (a) representa o sinal original. Na Figura 2(b), observa-se o sinal contaminado com ruído com SNR -5dB. Nas Figuras 2(c), 2(d), 2(e), 2(f) e 2(g) estão os resultados da filtragem utilizando, respectivamente, $\gamma = 250$, $\gamma = 200$, $\gamma = 150$, $\gamma = 100$ e $\gamma = 50$.

Para a situação mostrada na Figura 2, verifica-se que quanto menor o valor de γ , mais o sinal tende a se suavizar. No entanto, quanto maior o nível de suavização, maior a possibilidade de se perder propriedades desejadas do sinal. Sendo assim, é importante escolher um valor de γ adequado para uma determinada SNR, de tal forma que a filtragem remova componentes indesejáveis da série temporal e conserve as propriedades desejadas do sinal, de maneira a aproximar o máximo possível o sinal filtrado do sinal original.

Para selecionar qual é o melhor parâmetro para uma dada SNR, usamos o fator de redução de ruído calculado pela equação (2). Testamos algumas séries temporais, para verificar qual parâmetro é mais adequado para uma dada SNR. A Figura 3 mostra a evolução do fator de redução de ruído (2) para $SNR = -5dB$, encontramos $\gamma_{max} = 2,1535$ para $\gamma = 20$.

A partir da melhor escolha do parâmetro para uma série temporal com uma determinada SNR, pode-se comparar melhor a atuação do filtro de Kalman no sinal antes e após a sua aplicação. Por exemplo, a Figura 4 mostra a comparação entre uma série temporal com $SNR = -5$ (linha azul) e essa mesma série filtrada (linha vermelha) com $\gamma = 20$, o qual proporciona o melhor fator de redução de ruído ($\gamma_{max} = 2,1535$).

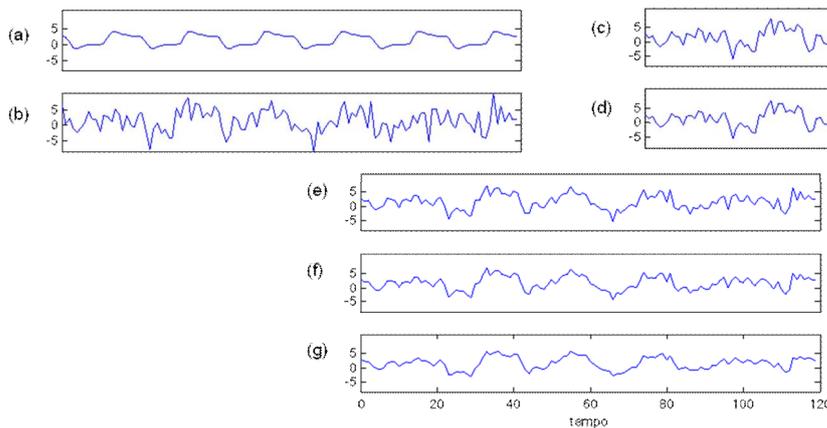


Figura 2- (a)Sinal original; (b) Sinal contaminado, $SNR = -5dB$; Sinal filtrado com: (c) $\gamma = 250$; (d) $\gamma = 200$; (e) $\gamma = 150$; (f) $\gamma = 100$; (g) $\gamma = 50$;

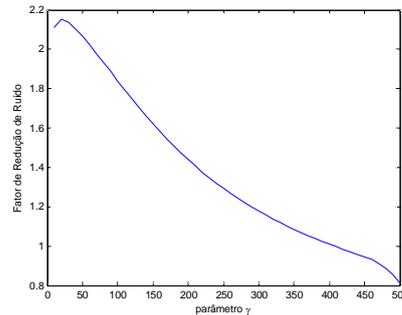


Figura 3- Fator de redução de ruído quando o parâmetro γ varia de 10 a 500 com incrementos de 10, para uma série temporal com $SNR = -5dB$.

Com base apenas na Figura 2, podemos supor que ocorre perda de amplitude significativa no sinal após a aplicação do filtro, mas quando comparamos o sinal filtrado com o sinal original, percebemos que o filtro teve um bom desempenho (Figura 4), recuperando boa parte da forma original do sinal.

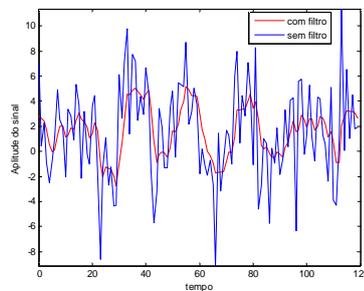


Figura 4- Comparação entre uma série temporal com $SNR = -5$ (linha azul) e essa mesma série filtrada (linha vermelha), com $\gamma = 20$ e $\gamma_{max} = 2,1535$.

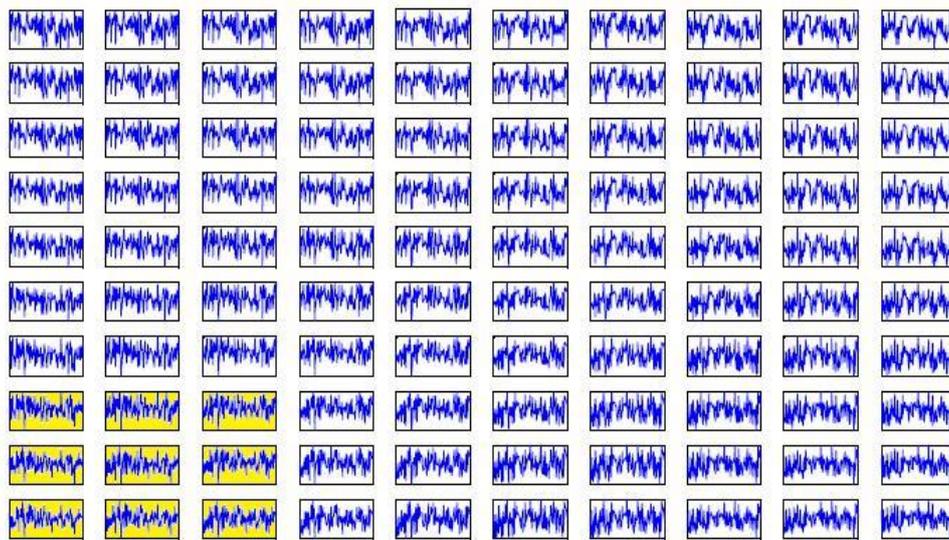
Analisando os resultados obtidos, observamos que o filtro é muito versátil. Observa-se que o filtro utilizado preserva a forma do sinal original. A qualidade dos resultados com o filtro de Kalman está diretamente relacionada à escolha do parâmetro γ .

Para verificar o desempenho do filtro nas séries temporais da fatia simulada, comparamos os dados pós-processados com e sem a atuação da filtragem de Kalman. Utilizou-se como ferramenta de comparação o algoritmo SOM na análise do conjunto de dados.

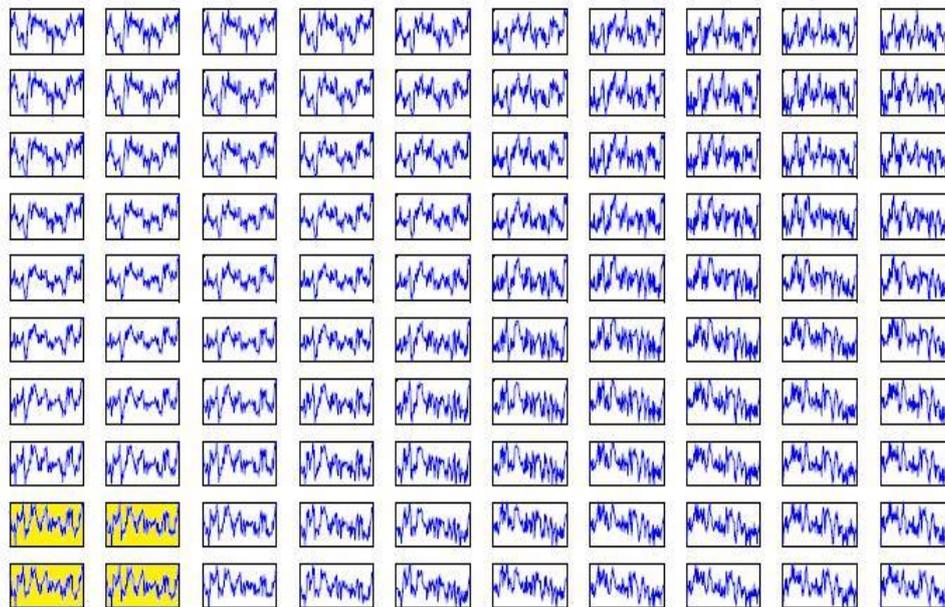
Para a primeira análise, consideramos o conjunto de dados da fatia simulada sem a aplicação do filtro de Kalman. Para esse conjunto de dados, deu-se início a etapa de treinamento do SOM em um total de 150 iterações. Após o término dessa etapa, o algoritmo SOM apresentou a grade de neurônios 10x10 Figura 5(a).

Na segunda análise, aplicou-se o filtro de Kalman no conjunto de dados da fatia simulada. Em seguida, iniciou-se a etapa de treinamento do SOM, mantendo-se o conjunto de pesos iniciais usados na análise sem a aplicação do filtro. A Figura 5 (b) mostra a grade de neurônios 10x10 para essa análise, embora em menor quantidade, os neurônios que representam a ativação possuem sinais mais nítidos.

Para gerar o mapa de ativações (Figura 6), é calculado um coeficiente de correlação entre todos os voxels das áreas correspondentes ao cérebro e a média dos pesos pertencentes ao agrupamento dos neurônios candidatos. O coeficiente de correlação entre estes dois sinais é usado como limiar para encontrar os voxels com maiores possibilidades de estarem ativos.



(a)



(b)

Figura 5 (a) Configuração final do SOM: grade 10x10 para os dados da fatia simulada sem a aplicação da filtragem de Kalman; (b) Configuração final do SOM: grade 10x10 para os dados da fatia simulada com a aplicação da filtragem de Kalman, o grupo de neurônios em amarelo corresponde aos padrões de atividade.

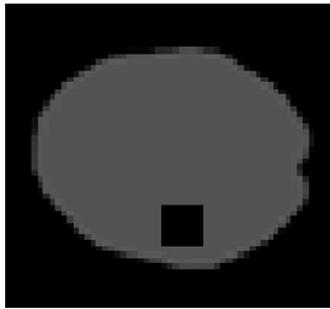


Figura 6 Mapa de ativações. As regiões pretas no interior do cérebro correspondem às regiões ativas computadas pelo SOM.

4 CONCLUSÕES

Neste trabalho foi apresentado a utilização do filtro de Kalman para filtrar sinais ruidosos das séries temporais de fMRI. Os resultados experimentais mostraram que com a filtragem de Kalman, podemos eliminar ruído de sinais de fMRI, alterando pouco os detalhes e a amplitude dos acontecimentos, preservando a morfologia característica do sinal.

REFERÊNCIAS

- [1] CAMPELO, A. D. S., 2010. **Análise de dados de Imagem por Ressonância Magnética Funcional utilizando Mapas auto-organizáveis**. Dissertação de Mestrado, Universidade Federal do Pará.
- [2] HAYKIN, S., 2001. **Redes Neurais Princípios e prática**. 2 edição, Bookman, São Paulo.
- [3] HUETTEL, S. A., SONG, A. W., e MCCARTHY, G., 2004. **Functional Magnetic Resonance Imaging**. Sinauer Associates.
- [4] KALMAN, R. E., 1960. **A new Approach to Linear Filtering and Prediction Problems**. ASME, Series D, Journal of Basic Engineering, 82 ; 35645.
- [5] KALMAN, R. E., BUCY, R. E., 1961. **New results in linear filtering and prediction theory**. ASME, Series D, Journal of Basic Engineering, 83 ; 956107.
- [6] LIAO, W., CHEN, H., YANG, Q., LEI, X., 2008. **Analysis of fMRI Data Using Improved Self-Organizing Mapping and Spatio-Temporal Metric Hierarchical Clustering**. IEEE Transactions on Medical Imaging, vol. 27, pp. 1472-1483.
- [7] ROCHA, M. P. C., LEITE, L. W. B., 2003. **Treatment of geophysical data as a non-stationary process**. Computational and Applied Mathematics, Vol. 22, N. 2, pp. 1496166.