

# Algoritmos Adaptativos para Filtragem de Sinal Cardíaco utilizando Transformada Wavelet

Guilherme Perin, Alice de Jesus Kozakevicius

Universidade Federal de Santa Maria - PPGI - GMICRO - LANA

97-105-900, Campus Camobi, Santa Maria, RS

E-mail: guilhermeperin@mail.ufsm.br, alicek@smail.ufsm.br

**Resumo:** Neste trabalho o algoritmo de Azzalini, Farge e Schneider, utilizado em análise de imagens é modificado, produzindo uma versão adaptativa e uma versão recursiva, ambas empregadas na filtragem de sinais cardíacos que apresentam diferentes níveis de ruído. Tanto a versão original, quanto as modificadas propostas neste trabalho são baseadas na aplicação da Transformada Wavelet de Daubechies em  $n$  níveis de fatoração do sinal analisado e na determinação de um limiar de corte ótimo empregado no processo de truncamento da série wavelet.

**Palavras-chave:** Transformada Wavelet, Filtragem adaptativa, Sinais cardíacos

## 1 Introdução

Nos últimos anos, muitos estudos têm sido realizados quanto à utilização de transformadas wavelet para filtragem de sinais cardíacos e demais sinais biomédicos. Vários métodos de filtragem de sinais cardíacos foram propostos como adaptações ao método desenvolvido por Donoho em [2]. Seu método baseia-se na determinação de um valor de corte (*threshold value*) para o truncamento (*hard thresholding*) da série wavelet de uma função, assumindo como hipótese que o ruído agregado inicialmente é do tipo gaussiano. A série wavelet do sinal poluído é então truncada levando-se em consideração o valor de corte estipulado. Através da transformada wavelet inversa obtém-se o sinal filtrado.

Em [8], a técnica de filtragem apresentada para sinais cardíacos combina truncamento (*hard thresholding*) com estratégias de amortecimento (*soft thresholding*) dos coeficientes da série wavelet. Tal método tem por objetivo corrigir os efeitos não esperados (fenômeno de Gibbs, atenuação da onda R, eliminação indesejada das ondas P e S) ocasionados pela aplicação de *hard* e *soft thresholding* separadamente a sinais cardíacos. Porém, esse método é eficiente apenas em poucos e selecionados níveis de decomposição da transformada wavelet, cujo controle não é automático.

O trabalho apresentado em [9] propõe um método de filtragem e detecção do complexo QRS baseado na transformada wavelet direta e em estratégias adaptativas de threshold, também fazendo referência ao trabalho de Donoho [2]. O trabalho consiste em encontrar dois valores de corte, definidos pelo autor como *threshold de limite superior* e *threshold de limite inferior*, de modo a enquadrar o complexo QRS entre tais valores.

A grande questão abordada por Zigel *at al* em [10] é a dificuldade de avaliação da qualidade da filtragem realizada, não só em termos quantitativos (erro quadrático médio), mas em termos qualitativos, de tal modo que propriedades do sinal, essenciais em diagnósticos, não sejam modificadas, distorcidas ou removidas do sinal analisado. A dificuldade em aplicar medidas de qualidade que levem em consideração propriedades morfológicas do sinal, que sejam relevantes para diagnósticos, está na obtenção de um banco de dados para a forma padrão do sinal e suas variações morfológicas de acordo com anomalias e/ou patologias cadastradas, indivíduos de diferentes faixas etárias, com biotipos distintos, etc.

A base de dados MIT-BIH [6], cujo acesso é gratuito e da qual foram considerados todos os sinais testados neste trabalho, fornece uma grande quantidade de exemplos de sinais cardíacos

que apresentam tanto padrões normais quanto padrões anormais para várias patologias catalogadas. No entanto, não há disponibilidade de uma base específica de padrões morfológicos, o que dificulta a aplicação da técnica proposta em [10].

O presente trabalho tem por objetivo a aplicação e análise de dois algoritmos baseados em transformada wavelet discreta de Daubechies, para encontrar um valor de corte que seja adequado para operações de truncamento (*hard thresholding*) de modo que a componente indejada possa ser eliminada sem afetar a integridade do sinal original. O primeiro algoritmo apresentado é denominado AFS-Modificado por ser inspirado no algoritmo apresentado por Azzalini, Farge e Schneider em [1]. Ele é baseado no espectro de frequência do sinal e faz uso da aplicação da técnica de *hard thresholding*. Diferentemente de [8], a filtragem através deste algoritmo não sofre grandes efeitos em função da quantidade de níveis da transformada wavelet direta, pois o limiar de corte é obtido adaptativamente através dos dados do sinal.

O segundo algoritmo proposto, denominado AFS, é uma adaptação a sinais unidimensionais do método apresentado em [1]. Novamente a série wavelet do sinal é truncada através da estratégia de *hard thresholding*. A diferença entre os algoritmos está na maneira com que o limiar de corte é obtido. Nesta segunda proposta, o algoritmo trabalha de maneira recursiva e tem por objetivo encontrar um valor de corte ótimo, que minimize o número de coeficientes truncados.

Este trabalho está organizado da seguinte maneira: a seção 2 apresenta um breve resumo sobre transformada wavelet. As seções 3 e 4 apresentam as modificações propostas neste trabalho para o algoritmo de filtragem. A seção 5 apresenta, através da relação sinal ruído, uma maneira de se analisar a qualidade da filtragem. E finalmente na seção 6 são apresentadas algumas aplicações dos algoritmos a sinais cardíacos do banco de dados [6].

## 2 Transformada Wavelet e Thresholding

O ambiente natural para a teoria das funções Wavelets é chamado de análise de multiresolução, que consiste na construção matemática de espaços  $V_j$  gerados por estas funções, suas translações e dilatações [7]. Um dos axiomas principais assume que  $\{0\} \subset \dots \subset V_{-1} \subset V_0 \subset V_1 \subset \dots \subset \mathcal{L}^2(\mathcal{R})$ . Neste trabalho considera-se a família de wavelets ortonormais com suporte compacto de Daubechies, sendo  $\phi(x)$  a função escala e  $\psi(x)$  a wavelet correspondente. Denotam-se os espaços da análise multiresolução por:  $V_j = [\phi_{j,k}(x)/j, k \in \mathcal{Z}]$ , sendo  $\phi_{j,k}(x) = 2^{j/2}\phi(2^jx - k)$  para  $j, k \in \mathcal{Z}$ . Analogamente  $W_j = [\psi_{j,k}(x)/j, k \in \mathcal{Z}]$ , com  $\psi_{j,k}(x) = 2^{j/2}\psi(2^jx - k)$ , para  $j, k \in \mathcal{Z}$ . Além disso, para todo nível  $j$  de resolução, vale a seguinte relação  $V_{j+1} = V_j \oplus W_j$ , em que  $\oplus$  representa a soma direta. Considerando-se ainda  $J$  o nível de resolução mais fino e  $J_0$  o nível de resolução mais grosseiro, tem-se  $V_J = V_{J_0} \oplus (\bigoplus_{j=J_0}^{J-1} W_j)$ . Assim, considerando  $J_0 \rightarrow -\infty$  e  $J \rightarrow \infty$ , obtém-se  $\mathcal{L}^2(\mathcal{R}) = \bigoplus_{j=-\infty}^{\infty} W_j$  e  $\bigcap_{j=-\infty}^{\infty} V_j = \{0\}$ . As funções escala e wavelet desta família satisfazem as seguintes relações de escala:

$$\phi_{j-1,l}(x) = \sum_{k=0}^{D-1} a_k \phi_{j,2l+k}(x) \text{ e } \psi_{j-1,l}(x) = \sum_{k=0}^{D-1} b_k \phi_{j,2l+k}(x), \quad (1)$$

cujos filtros  $a_k$  e  $b_k = (-1)^k a_{D-1-k}$  caracterizam as funções da família de Daubechies [3], sendo  $D = 2N$  e  $N$  representa o número de momentos nulos da wavelet escolhida.

A Transformada Wavelet Rápida [4], cujos dados iniciais são aproximados pelos valores discretos da função (sinal) para o nível mais fino de resolução é dada por:

$$c_{j-1,l} = \sum_{k=0}^{D-1} a_k c_{j,2l+k} \text{ e } d_{j-1,l} = \sum_{k=0}^{D-1} b_k c_{j,2l+k}. \quad (2)$$

Esta transformação define um mapeamento linear dos coeficientes  $\{c_{j,k}\}_{k \in \mathcal{Z}}$ ,  $j$  nível mais fino, em  $\{c_{j-1,k}\}_{k \in \mathcal{Z}}$  e  $\{d_{j-1,k}\}_{k \in \mathcal{Z}}$ . A fatoração de funções no espaço  $V_j$  em uma quantidade maior de níveis é obtida através da aplicação da mesma transformação na seqüência  $\{c_{j-1,l}\}_{l \in \mathcal{Z}}$  para obter as novas seqüências  $\{c_{j-2,l}\}_{l \in \mathcal{Z}}$  e  $\{d_{j-2,l}\}_{l \in \mathcal{Z}}$  e assim sucessivamente, até que o nível grosseiro

$J_0$  seja alcançado. Aqui  $J_0$  tanto pode ser um nível intermediário desejado, quanto pode ser o nível mais grosseiro contendo apenas um elemento em cada componente.

A transformada rápida inversa é dada por:

$$c_{j,l} = \sum_{n=n_1(l)}^{n_2(l)} c_{j-1,n} a_{l-2n} + d_{j-1,n} b_{l-2n}, \text{ com } \lceil \frac{l-D+1}{n} \rceil \equiv n_1(l) \leq n \leq n_2(l) \equiv \lfloor \frac{l}{2} \rfloor. \quad (3)$$

### Operação de Truncamento

A propriedade de possuir  $N$  momentos nulos das wavelets da família de Daubechies tem como consequência principal o fato de, para uma função suave, os coeficientes wavelets  $\{d_{j,k}\}_{k \in Z}$  decrescerem rapidamente [7]. Além disso, se uma função possuir descontinuidades em uma de suas derivadas, então os coeficientes wavelets de sua série irão decrescer mais lentamente apenas em uma vizinhança desta descontinuidade, permanecendo com decaimento rápido em regiões nas quais a função original é suave. Uma aplicação imediata disso é a possibilidade de se descartar coeficientes wavelet que sejam menores do que um certo valor de corte, sem perda significativa de "qualidade" do sinal, quando este é recuperado após a transformada inversa da série truncada. Aqui cabe salientar que este é o princípio fundamental por trás da compressão e análise de dados usando transformadas wavelet.

Na filtragem de sinais (biomédicos ou não), cuja técnica envolva aplicação de transformada wavelet associada à operação de truncamento de coeficientes wavelets da série, duas estratégias de truncamento (Thresholding) são muito utilizadas: as estratégias de *hard thresholding* e de *soft thresholding* [5, 8]. Ambas necessitam da obtenção prévia de um limiar de corte  $\lambda$  (threshold) que, aplicado aos coeficientes da série wavelet de uma função, possa selecionar informações de acordo com a suavidade do sinal analisado. A estratégia de Hard Thresholding está definida por:

$$Th_H(d) = \begin{cases} d, & \text{se } |d| \geq \lambda \\ 0, & \text{se } |d| < \lambda. \end{cases} \quad (4)$$

Neste trabalho, o foco central é a determinação do limiar de corte  $\lambda$  para, a partir dele, se retirar ruídos de alta frequência (informações expúrias) dos sinais cardíacos. Considera-se também em todos os experimentos numéricos a estratégia de Hard Thresholding, pois a operação de truncamento com esta estratégia tende a manter a forma de onda R, do complexo QRS e da onda P do sinal cardíaco quase sem alterações, como indicam os experimentos numéricos apresentados na próxima sessão.

## 3 O Algoritmo Adaptativo AFS - Modificado

Donoho em [2] propõe uma técnica de filtragem de coeficientes da série wavelet para um sinal original  $y = s + e$ , ou seja,  $y$  representado pela soma do sinal puro  $s$  com um ruído gaussiano  $e$ . A técnica proposta em [2] está fortemente baseada na hipótese de  $e$  ser um ruído gaussiano, cuja estimativa da variância do ruído é feita através desta hipótese. O limiar de corte  $\lambda$  é então determinado por Donoho através da variância do ruído gaussiano, cuja expressão é dada por:  $\lambda_U = \sigma \sqrt{2 \log_{10} N}$ . Este valor é denominado pelo autor como *threshold universal*.

No contexto de sinais biomédicos (cardíacos), ao contrário dos sinais analisados por Donoho, a componente de ruído é uma somatória de várias interferências que ocorrem durante a captação do sinal, e por consequência, de natureza desconhecida. Sendo assim, técnicas adaptativas para determinação dos valores de truncamento da série wavelet para sinais cardíacos têm apresentado resultados promissores tanto em processos de filtragem [5], quanto em processos de análise de componentes específicas do sinal, como por exemplo, complexo QRS, ondas P e Q [8, 9, 6]. Com o intuito de contribuir nessa linha, este trabalho descreve modificações e o uso de um algoritmo adaptativo que tem por objetivo estimar a variância da componente de ruído presente no sinal analisado e, através disso, obter um coeficiente de corte  $\lambda$  que seja coerente com este sinal.

Novamente considera-se  $y$  como sendo o sinal com ruído,  $s$  o sinal puro a ser estimado após a inversão da série wavelet truncada e  $e$  o ruído presente em  $y$ . O algoritmo adaptativo possui duas etapas fundamentais:

**Etapa 1: Inicialização - Obtenção do Limiar de Corte**

1.0. Obter o coeficiente de corte  $\lambda_{d_1}$ , considerando-se a estratégia de *hard threshold*. Para simplificar a notação, considera-se  $d_j = \{d_{j,k}\}_{k \in Z, \forall j}$ . 1.1. Aplicar a transformada wavelet direta ao sinal original  $y_0$ , obtendo um vetor que representa o sinal grosseiro  $y_1$  e um segundo vetor que representa um sinal de detalhes  $d_1$ , ambos com  $N/2$  pontos.

1.2. Calcular o desvio padrão  $\sigma_{d_1}$  do sinal de detalhes  $d_1$ , obtido no passo 1.1.

1.3. Calcular o coeficiente de corte  $\lambda_{d_1} = \sigma_{d_1} \sqrt{2 \log_{10}(N/2)}$ . Nota-se que o número do pontos no cálculo de  $\lambda_{d_1}$  é  $N/2$  ao invés de  $N$  como apresentado por Donoho em [2]. Isso diminui a magnitude do coeficiente de corte, o que resulta na preservação de informações importantes do sinal cardíaco.

**Etapa 2: Filtragem**

A segunda etapa do algoritmo atua de modo a filtrar o sinal original  $y$ .

2.1. Considerando o sinal  $y_1$  no nível  $n_1$  com  $N/2$  pontos, aplicar a transformada wavelet direta para  $n$  níveis.

2.2. Descartar todos os coeficientes  $d_1$  e aplicar a operação de truncamento com o coeficiente de corte  $\lambda_{d_1}$  aos coeficientes wavelets  $d_2, d_3 \dots d_n$ , determinados na etapa 2.1.

2.3. Utilizando os coeficientes  $d_1 = 0, d_2 \dots d_n$  e  $y_n$  obtidos no passo 2.2, aplicar transformada inversa para reconstruir uma aproximação do sinal. O resultado obtido no final desta etapa representa o sinal filtrado.

O coeficiente de corte  $\lambda_{d_1}$  é calculado apenas com o vetor que representa o sinal de detalhes  $d_1$ , obtido a partir da transformada wavelet direta para o primeiro nível de decomposição. No caso de um sinal cardíaco ter uma taxa de amostragem de 1000 amostras por segundo, no domínio da frequência esses valores estão associados a um espectro de frequências de 0 a 500 Hz. Para sinais cardíacos, as componentes importantes se concentram entre 0 e 120 Hz (ondas P, Q, R, S e T) de acordo com [6]. Portanto, as informações principais do sinal se concentram na primeira metade do espectro de frequências. Já a segunda metade do espectro de frequência representa a maior parte das componentes de ruído presentes no sinal cardíaco. Isso indica que coeficientes wavelets associados a altas frequências podem ser retirados do sinal, sem danificar a estimativa do sinal sem ruído.

Portanto, os filtros wavelets  $a_k$  e  $b_k$ , separam o sinal original  $y_0$  em componentes  $y_1$  e  $d_1$ , cujas frequências se situam na primeira e segunda metade do espectro, respectivamente. De forma análoga, as componentes  $y_2$  e  $d_2$  terão suas frequências situadas na primeira e segunda metades da faixa de variação de 0 a 250 Hz, e assim sucessivamente.

## 4 O Algoritmo Recursivo AFS

O algoritmo recursivo AFS proposto em [1] foi elaborado para análise de sinais bidimensionais (imagens). Aqui, é proposta uma adaptação deste algoritmo para sinais unidimensionais. O algoritmo AFS também se baseia na obtenção de um coeficiente de corte ótimo através da análise de um sinal original  $y = s + e$ ,  $s$  representando o sinal puro e  $e$  uma componente de ruído presente em  $y$ . A seguir as três etapas que caracterizam o algoritmo AFS são apresentadas com as adaptações necessárias para sinais unidimensionais, preservando-se a notação fixada em [1].

**Etapa 1: Inicialização**

1.1. Considerar a iteração inicial como sendo  $i = 0$ .

1.2. Aplicar a transformada wavelet rápida ao sinal  $y_0$ , contendo  $N$  pontos, para  $n$  níveis de decomposição, a fim de obter  $\bar{y}$ , que representa os coeficientes da série wavelet  $d_1, d_2 \dots d_n$  e  $y_n$ .

1.3. Calcular o desvio padrão de  $\bar{y}$ , e, a seguir, o coeficiente de corte  $\lambda_{\bar{y}} = \sigma_{\bar{y}} \sqrt{2 \log_{10}(N)}$ . Este desvio padrão difere da estimativa apresentada no algoritmo AFS Modificado, pois agora são tomados todos os valores da série completa de  $\bar{y}$ .

1.4. Aplicar a operação de truncamento com a estratégia de *hard thresholding* e com limiar de corte dado por  $\lambda_{\bar{y}}$  aos coeficientes de detalhes  $d_1, d_2 \dots d_n$ , obtidos a partir da transformada wavelet rápida de  $y_0$  em 1.2.

1.5. Armazenar em uma variável  $N_i$  o número de coeficientes de detalhes que foram descartados pela operação de truncamento realizada em 1.4.

1.6. Calcular o desvio padrão  $\sigma_i$  dos coeficientes que foram descartados em 1.4.

1.7. Calcular o limiar de corte  $\lambda_i = \sigma_i \sqrt{2 \log_{10}(N)}$ , obtido a partir do desvio padrão estimado em 1.6 e iniciar o laço principal.

**Etapa 2: Laço Principal-correção do valor inicial estimado**

2.1. Aplicar a operação de corte com limiar  $\lambda_i$  aos coeficientes de detalhes  $d_1, d_2 \dots d_n$  obtidos a partir da transformada wavelet rápida de  $y_0$ .

2.2. Armazenar na variável  $N_{i+1}$  o número de coeficientes wavelets descartados pela operação de corte em 2.1.

2.3. Calcular o novo desvio padrão  $\sigma_{i+1}$  de todos os coeficientes wavelets descartados em 2.1.

2.4. Calcular o limiar de corte  $\lambda_{i+1} = \sigma_{i+1} \sqrt{2 \log_{10}(N)}$

2.5. Se  $N_i = N_{i+1}$ , passar para a operação final. Caso contrário,  $i = i + 1$  e retorna ao passo 2.1.

**Etapa 3: Operação Final**

3.1. Aplicar a operação de corte com  $\lambda_{i+1}$  aos coeficientes de detalhes  $d_1, d_2 \dots d_n$  obtidos a partir da transformada wavelet rápida de  $y_0$

3.2. Reconstruir o sinal a partir da transformada wavelet inversa utilizando os coeficientes truncados  $d_1, d_2 \dots d_n$  e  $y_n$  obtidos no passo 3.1. O resultado obtido nesta etapa representa o sinal filtrado.

## 5 Medidas de Qualidade dos Algoritmos

O SNR (*Signal-to-Noise Ratio*) é uma medida que relaciona um parâmetro (potência, energia, variância) de um sinal  $y = s + e$  pelo mesmo parâmetro do ruído  $e$  presente neste sinal. Portanto, na avaliação de medidas do tipo SNR é fundamental o conhecimento da componente de ruído. Sendo assim, através da técnica de filtragem, busca-se ao mesmo tempo estimar  $s$  que é a componente limpa do sinal e a componente associada ao ruído. E a avaliação da qualidade da componente  $s$  se dá através das medidas envolvendo a componente  $e$ . Aqui, o parâmetro utilizado na análise é a variância:

$$SNR_y = 10 \log_{10} \left( \frac{\sigma_y^2}{\sigma_e^2} \right), \quad \sigma_y^2 = \frac{1}{N} \sum_{k=0}^{N-1} (y - \bar{y})^2, \quad \sigma_e^2 = \frac{1}{N} \sum_{k=0}^{N-1} (e - \bar{e})^2. \quad (5)$$

## 6 Aplicações e Resultados

Os testes numéricos nesta seção ilustram o potencial de filtragem de cada um dos algoritmos apresentados nas seções 2 e 3. A medida de qualidade utilizada na comparação das duas formulações é o SNR para a variância, amplamente utilizado na literatura. De acordo com [10] cabe observar que medidas como o erro quadrático médio podem mascarar perdas de propriedades relevantes para diagnóstico que ocorreram devido a uma filtragem exagerada. No entanto, essa forma de avaliar a qualidade do sinal estimado ainda segue sendo utilizada, uma vez que medidas mais específicas dependem de um número muito elevado de parâmetros de difícil determinação, como por exemplo, padrões morfológicos tanto normais quanto patológicos [10].

Na Figura (1), os gráficos das partes (a), (d), (g) e (j) apresentam sinais cardíacos ( $y$ ) com diferentes níveis de ruído. Em (b), (e), (h) e (k) estão os resultados da filtragem utilizando AFS Modificado e os gráficos (c), (i), (f) e (l) são as curvas obtidas do algoritmo recursivo AFS. Cabe ressaltar que quanto menor o valor de SNR, melhor é a estimativa do ruído (filtragem). Em todas as aplicações foram utilizadas a transformada wavelet de Daubechies com 3 momentos nulos (Db3). A Figura (2) apresenta os resultados da aplicação dos algoritmos AFS Modificado e AFS a um sinal ruidoso com uma taxa de amostragem de 1000 amostras por segundo, obtido da base de dados do MIT-BIH para sinais cardíacos normais [6]. A transformada wavelet direta (Db3) foi aplicada para 5 níveis de transformação. Pode-se observar que o formato do complexo QRS indicado na figura é preservado após a filtragem. A preservação dessa informação é importante tanto na classificação do sinal quanto na detecção de anomalias. A Figura (2 c) apresenta, também, a filtragem de um sinal cardíaco através de um filtro eletrônico [11]. Este método possui a desvantagem de atenuar o complexo QRS, além de realizar pequenas deformações nas ondas que caracterizam o sinal cardíaco. A Tabela (1) apresenta os valores de SNR em dB para os 5 níveis de transformação apresentados na Figura (2 b). Como se pode observar nesta tabela,

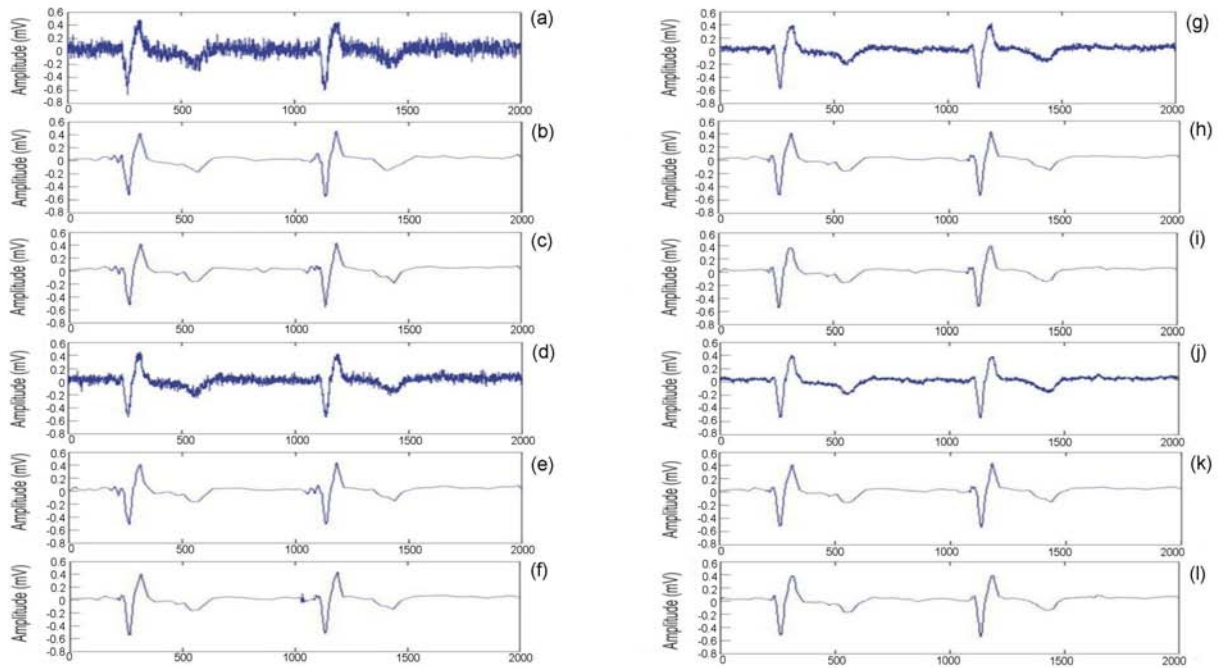


Figura 1: (a) Sinal original  $y$ , (b) aplicação de AFS Modificado em  $y$ , (c) aplicação de AFS em  $y$ , (d) Sinal original  $y$ , (e) aplicação de AFS Modificado em  $y$ , (f) aplicação de AFS em  $y$ , (g) Sinal original  $y$ , (h) aplicação de AFS Modificado em  $y$ , (i) aplicação de AFS em  $y$ , (j) Sinal original  $y$ , (k) aplicação de AFS Modificado em  $y$ , (l) aplicação de AFS em  $y$ .

os valores de SNR obtidos a partir da aplicação do algoritmo AFS Modificado são menores em relação aos valores obtidos com o algoritmo AFS, resultando na remoção mais eficiente do ruído.




Figura 2: (a) Resultados dos algoritmos AFS Modificado e AFS para o quinto e último nível de transformada. (b) Resultado da medida SNR para ambos os algoritmos para cada um dos 5 níveis da transformada DB3. (c) Filtragem de sinal cardíaco através de filtro eletrônico.

## 7 Conclusão

Neste trabalho, um algoritmo utilizado para análise de imagens é adaptado para o caso de sinais unidimensionais e ainda é modificado para realizar a filtragem adaptativa de sinais cardíacos através da transformada wavelet ortonormal. A adaptividade é obtida uma vez que o limiar de corte para o truncamento de coeficientes wavelets da série do sinal é calculado através dos próprios valores a serem analisados. Os algoritmos têm por objetivo estimar a variância do ruído presente no sinal, pois o limiar de corte procurado depende desta variância. O algoritmo AFS Modificado (o primeiro apresentado) baseia-se em uma análise das frequências do sinal analisado para decidir quais níveis da transformação podem ser descartados, sem causar dano na reconstrução do sinal. O segundo (adaptação do algoritmo AFS) atua de maneira recursiva

Níveis	SNR(dB) AFS Modificado	SNR(dB) AFS
3	13.83416	14.22505
4	13.18826	13.74593
5	12.54454	13.49551
6	11.96176	13.33080
7	11.72126	13.23393
8	11.65551	13.25220

Tabela 1: Razão Sinal-Ruído (SNR) para o AFS Modificado (coluna 2). SNR para a versão original do algoritmo AFS (coluna 3).

para estimar a variância do ruído, estabilizando ao longo do processo a quantidade de elementos retirados da série wavelet. Os resultados para os dois algoritmos são apresentados através da relação sinal-ruído tanto do sinal original, quanto do sinal filtrado e comparados ainda com uma filtragem eletrônica sem envolver transformada wavelet. O algoritmo adaptativo AFS-Modificado proposto realiza a filtragem com poucas operações, sendo que a transformada wavelet rápida para  $n$  níveis é realizada apenas uma vez. O algoritmo recursivo tende a manter um maior número de informações no processo de filtragem, fato explícito nos valores de SNR apresentados na seção 6, e além disso ele necessita de um maior número de operações para se chegar ao sinal filtrado. A medida SNR baseada na variância foi utilizada como forma de avaliar o desempenho dos algoritmos quanto à qualidade do sinal estimado.

## Referências

- [1] A. Azzalini, M. Farge, e K. Schneider, Nonlinear wavelet thresholding: A recursive method to determine the optimal denoising threshold, *Appl. Comput. Harm. Anal.* 18 (2005), no. 2, 177-185.
- [2] D. L. Donoho e I. M. Johnstone, "Wavelet threshold estimators for data with correlated noise", *J Royal Statist Soc, Vol. B* 59 no. 2,(1997) 319-351.
- [3] I. Daubechies, *Ten lectures on wavelets*, SIAM, Philadelphia, 1992.
- [4] M. Jansen, *Noise reduction by wavelet thresholding* (New York, Springer Verlag, 2000).
- [5] A. J. Kozakevicius, C. R. Rodrigues, R. C. Nunes, e R. Guerra Filho, *Adaptative ECG filtering and QRS detection using orthogonal wavelet transform*, (2006) Acta press, online.
- [6] MIT-BIH data base, online: [www.physionet.org/physiobank/database/mitdb](http://www.physionet.org/physiobank/database/mitdb). Acesso em 25 de Janeiro de 2009.
- [7] O. M. Nielsen, *Wavelets in scientific computing*. Ph.D. Thesis, Technical University of Denmark, 1998.
- [8] L. Su e G. Zhao, De-Noising of ECG Signal Using Translation- Invariant Wavelet De-Noising Method with Improved Thresholding, *Proceedings of the IEEE Engineering in Medicine and Biology 27th Annual Conference, China, September, 2005*.
- [9] X. Xu e Y. Liu, Adaptative Threshold for QRS Complex Detection Based on Wavelet Transform, *Conf Proc IEEE Eng Med Biol Soc.* (2005).
- [10] Y. Zigel, Arnon Cohen e Amos Katz, The Weighted Diagnostic Distortion (WDD) Measure for ECG Signal Compression, *Proceedings of the IEEE*, Vol. 47, No 11, November, 2000.
- [11] F. SILVEIRA, D. FLANDRÉ, "A Pacemaker Sensing Channel in CMOS on Silicon-on-Insulator", *IEEE Journal of Solid-State Circuits*, 2002.