

Artigo Original

Recebido em 11/06/2003 e aceito em 18/02/2004

**Estudo comparativo entre
funções wavelet e suas
diferentes aplicabilidades
em reconhecimento de padrões
epileptogênicos em
eletroencefalograma**

*Comparative study concerning to
wavelet functions and its different
applicabilities to pattern recognition
in electroencephalogram*

**Fernanda I. M. Argoud,
Fernando M. de Azevedo,
José Marino Neto**

Instituto de Engenharia Biomédica – IEB
Departamento de Engenharia Elétrica - EEL
Centro Tecnológico - CTC
Universidade Federal de Santa Catarina - UFSC
Florianópolis, SC, Brasil, CEP 88040-900
Fone (0XX48)331-9594, Fax (0XX48)331-9280
E-mails: fargoud@ieb.ufsc.br,
azevedo@ieb.ufsc.br, marino@ccb.ufsc.br

Resumo

A transformada wavelet discreta (DWT) fornece uma representação de sinais precisa no domínio tempo-frequência, gerando poucos coeficientes com mínima perda de informação, devido a sua capacidade potencial de oferecer alto grau de correlação com o sinal a ser decomposto ou com o padrão a ser reconhecido. Embora este atributo dependa fundamentalmente da escolha da função wavelet a ser utilizada para cada tipo específico de padrão, frequentemente a metodologia de seleção relatada não fica clara. O presente estudo descreve e propõe uma metodologia destinada a maximizar o aproveitamento da DWT na detecção automática de padrões relacionados à epilepsia (chamados de eventos epileptogênicos), em sinais de eletroencefalograma (EEG). Com base em uma metodologia estatística simples (teste Z-score), determinou-se a melhor função wavelet dentre as mais utilizadas. Esta função wavelet específica provou ser a mais apta em separar os padrões epileptogênicos da atividade de fundo normal em EEG, no espaço de características. Os testes demonstraram que apenas algumas das funções wavelet atualmente utilizadas são aplicáveis à tarefa de ressaltar eventos epileptogênicos com relação à atividade de fundo nos sinais de EEG. Os valores de limiar para detecção após a DWT foram investigados e obtiveram-se taxas de sensibilidade e especificidade simultâneas de 88,7% para o método.

Palavras-chave: Detecção automática de espículas, Eletroencefalograma, Epilepsia, Transformada wavelet.

Abstract

The discrete wavelet transform (DWT) provides accurate signal representation in time-frequency domain, generating few coefficients with minimum information loss, due to its potential for highly correlating with the signal to be decomposed or with the pattern to be recognized. Although this attribute critically depends on the selection of a wavelet function suitable for use with a given specific pattern, frequently the method reported for this selection is not clear. The present study describes and proposes a methodology designed to maximize the use of DWT in automatic detection of epilepsy-related patterns (or epileptogenic events), in electroencephalographic recordings (EEG). Based on a simple statistical methodology (Z-score test), we could determine the best wavelet function, among those usually employed. This particular wavelet function proved to have greater ability to separate epileptogenic patterns from normal background activity in EEG features space. Tests demonstrated that only a few of the currently used wavelet functions are applicable to emphasizing epileptogenic events over background activity in EEG signals. Threshold values used after DWT were also investigated and sensibility and specificity rates of 88.7% were simultaneously obtained by this method.

Keywords: Automatic detection of spikes, Electroencephalogram, Epilepsy, Wavelet transform.

Extended Abstract

Introduction

The wavelet transform (WT) is a signal representation in time-frequency domain, calculated by correlating a signal with dilated and time translated versions of a basic function: the wavelet mother, or wavelet function. WT can generate a few number of coefficients with minimum information loss, due to its potential for highly correlating with the signal to be decomposed or with the pattern to be recognized. However, this capacity has a critical dependence on the selection of the wavelet function to be used on WT, due to distinct features of each wavelet (like the order of decomposition filters, existence or not of reconstruction filters, support length, vanishing moments, symmetry with respect to y-axis, orthogonality, etc) and due to different degrees of morphological similarity between the wavelet function and the pattern to be represented or recognized. In spite of, empirical or vague procedures are frequently used for this selection.

This article investigates a criterion to selection of wavelet functions and describes the development and application of a methodology designed to maximize the use of WT in automatic recognition of patterns in electroencephalographic signals (EEG).

These patterns are named "epileptogenic events" because are related to epilepsy and are frequently found in EEG signals from epileptic patients. The commonest kind of epileptogenic events are spikes and sharp waves.

Material and Methods

We treated epileptogenic and background activities, in EEG signals, as independent processes, which could be separated with a simple statistical methodology (Z-score test), after wavelet analysis.

The capacity of generate high values to z in the vicinity of spike's peak was evaluated to 47 different wavelet functions. The wavelet functions were applied to eighteen EEG signals, with 15-seconds of duration each, which contained at least one spike or sharp wave. Reconstructed detail coefficients in scales 1 to 5 were evaluated using Z-score test and the procedure was repeated also to epochs of 4 seconds of duration, around the spikes or sharp waves. This was done to prove that previous results referred, in fact, to epileptogenic events.

We have observed that Coiflet1 and Biorthogonal2.2 showed the best results, to levels of decomposition 2 and 3.

Results

Among those 47 wavelet functions usually employed, we have determined the wavelet function that offered highest separation of epileptogenic activities patterns from background EEG, in features space (generally with $z > 8$, in the spike's vicinity): Coiflet1.

Also, tests demonstrated that most of the wavelet families examined (of 36 wavelet functions) could not emphasize epileptogenic events over background activity in EEG signals.

It was observed, also, that levels 2 and 3 showed best results in emphasize epileptogenic events, while higher scales showed no relevant information and level 1 suffered to much influence from noises and high-frequency artifacts.

To avoid noises and muscle activity influence, detail coefficients of level 1 were not considered, because it retained signal's highest frequency information.

So, Coiflet1 function was applied to 27 EEG files, randomly chosen, and a threshold value was used to detection. A balanced value, between sensibility and specificity was achieved in 88.7%, to a threshold of 5.34 standard deviations from mean.

Discussion

The wavelet functions morphologically similar to signal to be decomposed will be more efficient in representing such signals, than wavelet functions more different. However, in spikes detection, choice of wavelet function has been done without formal criteria or in an empiric manner.

In this application, Coiflet1 showed to be an adequate tool to differentiate spikes and sharp waves from background activity, while a number of wavelet functions (like Biorthogonals 1.1, 1.3, 1.5, 6.8, Daubechies 1, 6, 9, 19 and Symlet 6) could not generate outlier coefficients to these events. It means that these wavelet functions were not appropriated to decompose EEG signals, aiming at spike recognition.

Virtually, levels 2 and 3 concentrated all relevant information about epileptogenic events, although level 2 have suffered influence from high-frequency noise and muscle activity, thus generating more false-positives, and level 3 have been affected by ocular movements and blinks, decreasing specificity.

Wavelet Transform must be associated with other signal processing tools, in order to improve detection and classification performance, but proved to be efficient as a pre-scanning tool applied to multichannel EEG signal. We considered this work as a preliminary study to a methodology of appropriated choice of wavelet functions to tasks in EEG processing.

Introdução

A transformada wavelet (TW) é uma ferramenta que permite representação tempo-freqüência de sinais. Esta representação é adequada para sinais não estacionários, permite boas resoluções simultaneamente em tempo e freqüência e pode ser aplicada em tempo real, através de algoritmo rápido.

A TW tem sido largamente utilizada como ferramenta auxiliar para reconhecimento de padrões, codificação e compressão de dados, eliminação de ruído, decomposição de sinais ou séries temporais, etc (apud Mallat, 1998; apud Sheng, 1996). No entanto, menos freqüentes são a formalização de procedimentos e os questionamentos quanto à aplicabilidade desta ferramenta (Bruns, 2004; Moulin e Mihçak, 1998; Gopinath et.al., 1994).

Uma das grandes questões na utilização da TW é a determinação da “melhor” função wavelet, ou “wavelet mãe”, a ser utilizada com um tipo particular de sinal. E os autores deste artigo acreditam que a capacidade da TW em representar ou decompor uma determinada função tem uma dependência crucial da função wavelet utilizada.

O objetivo deste trabalho é investigar esta hipótese e estabelecer um critério para escolha de uma função wavelet mãe mais correlacionada com o tipo de padrão que se quer reconhecer e ressaltar nos sinais de EEG (no caso, os eventos epileptogênicos).

A Transformada Wavelet

A transformada wavelet consiste em um tipo de repre-

sentação tempo-freqüência de sinais que pode permitir que se tenha simultaneamente boa resolução em tempo (para ressaltar eventos “rápidos” ou transitórios dos demais) e em freqüência (para representar claramente as freqüências de interesse).

A transformada wavelet contínua (CWT) consiste na correlação cruzada entre um sinal $f(t)$ e uma família de funções que vão variar na forma e na largura, chamadas “funções wavelet” (Equação 1). Estas funções são versões dilatadas ou contraídas, por uma variável contínua a chamada “escala”, de uma função básica $h(t)$ chamada “wavelet mãe” (Sheng, 1996), formando o que se chama de “família wavelet”:

$$CWT_{a,\tau} [f(t)] = \int_{-\infty}^{+\infty} f(t)h_{a,\tau}^*(t)dt \tag{1}$$

$$h_{a,\tau}(t) = \frac{1}{\sqrt{a}}h\left(\frac{t-\tau}{a}\right) \tag{2}$$

Na transformada wavelet discreta (DWT), as variações dos fatores de escala a e de translação no tempo τ são discretas (normalmente em variações diádicas: $a=2^j$, onde j é o nível de decomposição), o que elimina parte da redundância inerente à CWT. A DWT pode ser implementada através do algoritmo de lifting (Sweldens, 1996), o qual utiliza bancos de Filtros Espelhados em Quadratura com Multirresolução (QMF). Ou seja, um conjunto de filtros $H(t)$ vai extrair as características de baixa freqüência (ou “aproximações”) do sinal, enquanto um conjunto de filtros $G(t)$ extrairá as características de altas freqüências (ou “detalhes”) do sinal

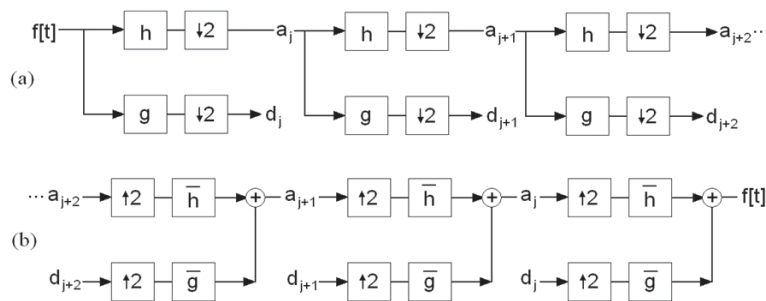


Figura 1. Aplicação de filtros Espelhados em Quadratura com Multirresolução a um sinal discreto $f[t]$. (a): o esquema de Lifting implementa uma filtragem em cascata com h e g , seguida de uma decimação (por um fator de 2), gerando os componentes de aproximação a_j e detalhe d_j , onde j é o nível de decomposição (b): o algoritmo de transformada inversa reconstrói progressivamente cada a_j pela adição das componentes resultantes a_{j+1} e d_{j+1} , após uma superamostragem (inserção de zeros). (Modificado de Mallat, 1998). **Figure 1.** Application of Quadrature Mirror filters to a discrete signal $f[t]$. (a): The lifting scheme implements a cascade filtering with h and g , followed by a decimation (by a factor 2), generating the approximation a_j and detail d_j coefficients, where j is the decomposition level. (b): the inverse transform algorithm gradually reconstructs each a_j by adding resulting components a_{j+1} and d_{j+1} after an oversampling (zero insert-ing). (Modified from Mallat, 1998).

$x(t)$ (Figura 1). Ambos os filtros ortogonais $H(t)$ e $G(t)$ são derivados da família wavelet utilizada.

A transformada wavelet está amplamente descrita na literatura e maiores detalhamentos acerca da teoria e aplicações podem ser obtidos em Mallat (1998) e Daubechies (1992).

O EEG e a epilepsia

A epilepsia é uma condição crônica, ou um grupo de doenças, de alta prevalência e, no entanto, ainda pouco conhecida e explicada pela ciência.

Já o sinal de eletroencefalograma (EEG) é considerado o método, por excelência, de investigação das epilepsias (Fourth Epilepsy Teaching Weekend, 1993; O'Donohoe, 1982). A relevância de se estudar o sinal de EEG, para o diagnóstico de epilepsias, incide no fato de que normalmente neste serão encontradas alterações eletrográficas significativas em pacientes epiléticos. Os tipos mais frequentes de alterações são as "espículas" e as "ondas agudas" interictais, as quais diferem entre si basicamente pela duração do evento (a espícula é mais rápida). Estas atividades bioelétricas apresentam morfologia espicular, aguda e/ou rítmica (Figura 2), ou seja, que se destaca visualmente da atividade de base do EEG, e normalmente são consideradas epileptogênicas (associadas ou originadas por distúrbio epilético) (Fourth Epilepsy Teaching Weekend, 1993; O'Donohoe, 1982).

O sinal de EEG, porém, apresenta algumas características inerentes que dificultam sua análise automática, em computador. Em primeiro lugar, é bastante afetado por ruídos, principalmente os provenientes do equipamento e do próprio paciente (como o ruído muscular, advindo da atividade elétrica dos músculos do paciente - EMG- e o ruído por atividade ocular, EOG). Além disto, o EEG pode ser classificado como um sinal complexo e ergódico (aleatório, estacionário e cujas médias temporais de cada experimento são invariantes no tempo) e com morfologia extremamente variável de




Figura 2. Trecho de sinal de EEG com espícula ao centro, superposta à atividade de fundo. **Figure 2.** Period of EEG signal with spike in the center, superimposed to the background activity.

paciente para paciente e em um mesmo paciente, sob estados mentais e comportamentais distintos.

Uma revisão recente realizada por Wilson e Emerson (2002) descreve e compara os trabalhos mais relevantes em termos de detecção automática de espículas em sinais de EEG.

Escolha da função wavelet para reconhecimento de padrões epileptogênicos

Em trabalhos que utilizam a TW especificamente em reconhecimento de padrões epileptogênicos em EEG, normalmente a escolha da função wavelet é arbitrária ou empírica (Schiff *et. al.*, 1994; Kalayci e Özdamar, 1995; Dümpelmann e Elger, 1999; Khan e Gotman, 2003). Já outros autores aparentemente optam pela escolha de funções wavelet que possuam forma analítica e função de transferência literal, como por exemplo a wavelet *spline* quadrática. Por fim, alguns autores consideram que não haveria diferença significativa em se aplicar uma ou outra função wavelet à tarefa (Khan e Gotman, 2003).

Vários trabalhos foram desenvolvidos, quanto à escolha ou desenvolvimento do conjunto ótimo de filtros QMF para representação ou compressão de sinais (Tsatsanis e Giannakis, 1995; Moulin e Mihçak, 1998; Vaidyanathan, 1998; Vaidyanathan e Kirac, 1998). No entanto, muitos deles envolvem formulações matemáticas complexas e exigem conhecimento dos conteúdos de densidade espectral referentes aos diferentes eventos e atividades a serem representados, o que muitas vezes também é inviável em termos de sinal de EEG, dada a variabilidade dos dados.

Crítérios para separação dos padrões

A abordagem escolhida foi a de se tratar os dois padrões que se queria separar no sinal de EEG (a atividade normal de fundo e a atividade epileptogênica), como atividades estatisticamente independentes entre si e testar a TW como ferramenta de separação destas atividades.

De fato, os mecanismos neuronais que geram os focos epiléticos, que por sua vez dão origem às alterações eletrográficas epileptogênicas, são distintos dos mecanismos que geram os padrões ditos "normais", encontrados em sinais de EEG. E apesar de as amplitudes médias típicas de espículas e ondas agudas serem normalmente maiores que as amplitudes nos ritmos de fundo do EEG, as amplitudes instantâneas das duas atividades são de mesma ordem (Figura 2). Além disto, o EEG apresenta diversos outros ritmos e eventos, muitos deles com morfologias bastante semelhantes

aos eventos epileptogênicos (e sendo por isto chamados “epileptiformes”), de magnitudes compatíveis ou superiores. Este fato impede o uso da amplitude, ou energia do sinal, como critério de separação no reconhecimento de padrões epileptogênicos.

Estatisticamente, atividades distintas coletadas em uma mesma amostra apresentam distribuições, valores esperados (médias μ) e dispersões (variâncias σ^2) distintos. Um “outlier”, por exemplo, é um valor observado que está a uma distância estatística anormal dos outros valores da amostra e que pode ser devido a um erro de amostragem ou devido a uma fonte de informação desconhecida, na população. E quanto mais discrepantes forem os valores, mais independentes serão as atividades entre si.

Por se tratar de um cálculo de correlação, a função wavelet morfologicamente mais semelhante, mais correlacionada com o padrão epileptogênico tenderá a gerar os maiores coeficientes no sinal transformado e as maiores amplitudes (outliers) no sinal reconstruído para as espículas, aumentando teoricamente a discrepância entre estas e a atividade de fundo.

Assim, procurou-se encontrar a(s) função(ões) wavelet mãe, a serem aplicadas à DWT de sinais de EEG, que sejam mais correlacionadas à atividade epileptogênica e menos correlacionadas à atividade normal de fundo e que gerem as amplitudes mais discrepantes, relativas às espículas, nos sinais reconstruídos.

Arquivos de teste

Para comprovação das proposições acima, foram selecionados 18 arquivos de um canal, durante 15 segundos cada, contendo sinais de EEG de superfície, de pacientes comprovadamente epiléticos.

Os registros foram obtidos junto ao Montreal Neurological Institute, Montreal, Canadá e contam com 32 canais, frequência de amostragem de 100 Hz, montagem tipo Zigomática bipolar. Os 7 pacientes foram rigorosamente selecionados no próprio Instituto e os registros foram adquiridos durante crises eletrográficas, mais 30 minutos antes e 30 minutos após, para garantir a ocorrência de diversos eventos epileptogênicos.

Destes 18 arquivos, 9 contam com espículas marcadas pelos eletroencefalografistas como “Perfeitas” e 9, com espículas marcadas como “Ordinárias”.

Não foram realizadas filtragens adicionais para eliminação de ruídos e artefatos oculares ou de movimento de paciente, presentes nos sinais de EEG, de forma a testar-se também a robustez da TW aos eventos epileptiformes.

Metodologia de comparação entre as funções wavelet

Para realizar a transformação wavelet, foram selecionadas as funções wavelet mãe mais conhecidas e utilizadas, as que possuíssem filtros de reconstrução e melhores propriedades de regularidade, suporte compacto, simetria, etc (Sheng, 1996). Sobretudo, as funções wavelet deveriam guardar alguma semelhança com a morfologia de um evento tipo espícula (para maior correlação).

As funções wavelet utilizadas foram (Mallat, 1998; Sheng, 1996):

- Biortogonais: 1.1, 1.3, 1.5, 2.2, 2.4, 2.6, 2.8, 3.1, 3.3, 3.5, 3.7, 3.9, 4.4, 5.5 e 6.8;
- Coiflets: 1 a 5;
- Daubechies: 1 a 20;
- Symlets: 2 a 8.

Além disto, para cada uma destas 47 funções, aplicadas a cada um dos 18 sinais com espículas, calculou-se a DWT até a escala $a=2^5$ (nível de decomposição $j=5$). Isto porque sinais de EEG dificilmente apresentam componentes wavelet significativas após o nível de decomposição 5 (Kalayci e Özdamar, 1995), que filtra componentes da ordem de 2 Hz (Tabela 1).

Para cada uma destas decomposições wavelet foi calculado o sinal recomposto de 15 segundos, de forma a isolar no tempo as componentes wavelet para cada escala a e cada função wavelet mãe. Para isto segue-se o Esquema de Lifting (Figura 1): cada vetor de coeficientes de detalhes do nível de decomposição n é superamostrado por um fator de 2 e submetido ao filtro de reconstrução espelhado $\bar{g}[n]$. A partir disto, ele é novamente superamostrado e submetido ao filtro de reconstrução $\bar{h}[n]$ ($n-1$) vezes, até gerar-se o sinal de detalhe reconstruído no tempo.

E tal como nos sinais originais, nos reconstruídos a diferenciação visual entre a espícula e a atividade de fundo deu-se mais pela distância relativa entre o pico de energia e a atividade de fundo média, que pela distância absoluta entre ambos (a qual variava consideravelmente).

Assim, sobre os sinais recompostos, aplicou-se o teste Z-score para amostra, o qual representa a distância entre o valor do dado e a média, em desvios padrão:

$$Z_i = \frac{x_i - \bar{x}}{s} \quad (3)$$

onde, z_i é o valor de z para cada ponto da amostra, x_i é o valor do ponto i da amostra, \bar{x} é a média e s é o desvio padrão.

O teste Z-score foi utilizado devido à grande variabilidade das amplitudes dos eventos em sinais de EEG e à superposição de eventos epileptiformes (não-epileptogênicos) à atividade de fundo, as quais inviabilizam a aplicação de uma simples *limiarização* de amplitudes ou picos de energia, como critério de reconhecimento. Além disto, o teste é um método estatístico de representação de informações em amostras bastante robusto com relação aos próprios valores discrepantes, os quais influenciam os valores de médias nas amostras (Fallon e Spada, 1997). A heurística estabelece que eventos significativos (e não oriundos de erro de medida) com valores de z maiores que 3 devem ser classificados como *outliers* (Fallon e Spada, 1997).

Assim, as funções wavelet mãe que não puderam oferecer valores de z superiores a 4, para nenhum valor de escala e para nenhum sinal com espícula foram eliminadas, quais sejam: Biortogonal1.1, Biortogonal1.3, Biortogonal1.5, Daubechies1 e Daubechies19.

As funções wavelet mãe que geraram z maior que 4, porém para eventos outros que não as espículas (como por exemplo, o próprio transitório das bordas do sinal ou para eventos epileptiformes), também foram eliminadas, quais sejam: Biortogonal6.8, Daubechies6, Daubechies9 e Symlet6.

Um algoritmo foi também criado para verificar se os valores discrepantes de cada arquivo coincidiam com o instante de ocorrência de uma espícula, ou estavam dentro de uma vizinhança de 4 pontos, centrada no ponto de ocorrência da espícula¹.

A partir destes dados, gerou-se uma série de 18 tabelas, contendo, para cada uma das 47 funções:

- Valor de z máximo encontrado no sinal recomposto;
- Índice de ocorrência do máximo (para verificação de coincidência);
- Escala onde ocorreu o máximo;
- O z máximo encontrado na escala 2 (normalmente a escala onde as espículas parecem mais acentuadas, em relação à atividade de fundo);
- O índice de ocorrência do máximo, para a escala 2.

O procedimento foi repetido também, para arquivos com duração de apenas 4 segundos (2 antes, 1 durante e 1 após a ocorrência da espícula), de forma a “concentrar” a análise em torno das espículas. Os resultados obtidos foram ainda mais consistentes e os valores de z obtidos no instante de ocorrência das espículas, para grande parte das funções wavelet mãe, ultrapassou o valor 8.

¹ As bases wavelet provocam atrasos de fase no sinal transformado, gerando estas diferenças nos índices do sinal antes e após a transformação. Porém, quando a diferença foi expressiva, o ponto de máximo desvio foi considerado como não tendo sido gerado pela espícula.

Todas estas informações foram cruzadas e chegou-se, finalmente, a duas funções wavelet mãe que se destacaram consideravelmente das demais, por apresentarem os valores de z mais elevados, na vizinhança das espículas: a Biortogonal2.2 e a Coiflet1.

Para fins de tabulação, os parâmetros calculados foram acumulados em frequências, e a Tabela 2 resume os resultados obtidos, apenas com as 11 funções wavelet que apresentaram melhores resultados:

- 1P – frequência com que a função wavelet gerou o maior valor de z , e para o instante de ocorrência da espícula;
- 5P – frequência com que a função wavelet ficou entre as 5 que geraram maiores valores de z e para o instante correto;
- > 8 – frequência com que a função wavelet gerou valores de z , para um determinado nível, superiores a 8 e para o instante correto;
- > 10 – frequência com que a função wavelet gerou valores de z , para um determinado nível, superiores a 10 e para o instante correto;
- Pto – frequência com que um ponto de maior z para a função wavelet coincidiu exatamente com o ponto (índice) de ocorrência (pico, em módulo) da espícula, para um determinado nível de decomposição;
- Ld – frequência com que um ponto de maior z para a função wavelet ficou imediatamente adjacente com o ponto (índice) de ocorrência da espícula, para um determinado nível de decomposição;
- Dv – frequência com que um ponto de maior z para a função wavelet ficou próximo, porém não na vizinhança da espícula, para um determinado nível de decomposição;
- NB – frequência com que um ponto de maior z para a função wavelet não coincidiu, absolutamente, com o período de ocorrência da espícula, para um determinado nível de decomposição.

Testes de aplicação da função Coiflet1 à detecção de padrões epileptogênicos

Tendo sido encontrada uma função wavelet mais correlacionada com eventos epileptogênicos, passou-se à aplicação da função Coiflet1 aos sinais de EEG e posterior reconstrução no tempo, de forma a testar-se especificamente a capacidade desta função em ressaltar os eventos, para detecção e reconhecimento.

Foram utilizadas, nesta etapa, 27 épocas de 15 segundos cada, selecionadas aleatoriamente e provenientes dos 7 pacientes epiléticos.

Verificou-se que as escalas 2² e 2³ foram as que geraram os mais altos valores para os parâmetros z

Tabela 1. Escalas wavelet e suas pseudo-freqüências correspondentes, para sinais amostrados a 100 Hz. As freqüências típicas de alguns eventos em EEG também são situadas na tabela (Fontes: O'Donohoe, 1982; Fourth Epilepsy Teaching Weekend, 1993; Speckmann e Elger, 1993). **Table 1.** Wavelet scales and its corresponding pseudo-frequencies, to signals sampled at 100 Hz. Typical frequencies of some EEG events also are situated in the table (Fonts: O'Donohoe, 1982; Fourth Epilepsy Teaching Weekend, 1993; Speckmann e Elger, 1993).

ESCALA	BANDA PASSANTE 3dB [Hz]	RITMOS E EVENTOS EM EEG DE ESCALPO
$a = 2^1$	25,0 ~ 50,0	espícula, ruído muscular (EMG) e de equipamento
$a = 2^2$	12,5 ~ 24,0	β , espícula, ruídos, fuso do sono
$a = 2^3$	6,2 ~ 12,0	α , Complexo K, ritmo Mu, espícula, onda aguda, EOG
$a = 2^4$	3,1 ~ 6,0	θ , onda lenta, onda aguda, complexo-espícula-onda (CEO)
$a = 2^5$	1,6 ~ 3,0	δ

Tabela 2. Resultados finais da análise comparativa entre funções wavelet, para processamento de sinais de EEG com padrões epileptogênicos. A função Coiflet1 (em destaque) apresentou os melhores valores de parâmetros, seguida pela função Biortogonal2.2. **Table 2.** Final results of comparative analysis among wavelet functions, to processing of EEG signals with epileptogenic patterns. Coiflet1 function (detached) showed the best parameter values, followed by Biorthogonal2.2 function.

Função Wavelet	1P	5P	>8	>10	Pto	Ld	Dv	NB
Biortogonal2.2	4	14	12	5	11	3	1	3
Biortogonal2.4	3	11	8	3	10	5	3	0
Biortogonal2.6	1	12	11	3	8	4	5	0
Biortogonal2.8	0	8	9	1	10	4	3	2
Biortogonal4.4	0	7	7	1	10	5	2	1
Biortogonal5.5	0	1	4	0	7	4	7	0
Coiflet1	7	16	14	5	11	4	1	2
Coiflet2	0	6	10	3	9	4	5	0
Daubechies2/ Symlet2	0	7	10	0	7	4	6	1
Daubechies3/ Symlet3	3	5	8	3	7	6	5	0
Symlet4	0	3	6	2	10	3	4	1

(Figuras 3 e 4). Com ligeira vantagem para o nível de decomposição 2, já que o nível 3 foi mais sensível a artefatos por movimentos musculares e oculares, presentes no EEG. O nível 2 foi também o mais "localizado" no tempo.

Ficou claro também que o nível 1 de escala, apesar de captar facilmente eventos rápidos como as espículas, é o mais afetado também por ruídos de alta freqüência, razão pela qual foi abandonado na análise.

Sobre os sinais reconstruídos aplicou-se um limiar de detecção arbitrado com valor inicial de $z=7,0$, e verificaram-se os picos de energia em cada trecho. Em caso de ultrapassagem do limiar, considerava-se uma detecção positiva de evento epileptogênico.

Os testes mostraram que a aplicação individual da TW não seria suficiente para um sistema relativamente preciso de detecção de espículas, pois a sensibilidade do algoritmo foi baixa (em torno de 65%), o que significa que grande parte dos eventos positivos não foi detectada. Cerca de 85% das espículas e

ondas agudas não detectadas apresentavam baixos valores de energia e amplitude (Figura 5), gerando por consequência baixos valores de z , o que causou os falsos-negativos.

Por outro lado, a especificidade obtida foi de 97,7%, indicando que o algoritmo foi capaz de diferenciar espículas e ondas agudas detectadas, da atividade normal de fundo e ocasionais eventos epileptiformes. As falsas detecções ocorridas deveram-se basicamente à presença destes eventos epileptiformes, os quais são freqüentes em sinais de EEG e morfologicamente semelhantes aos eventos epileptogênicos, tais como ruídos, movimentos musculares e oculares e, em menor escala, ao ritmo alfa.

Variou-se então o limiar de detecção para se levantar as curvas de desempenho em função deste, como ilustrado na Figura 6. Note-se que para valores de limiar inferiores ao do ponto de cruzamento das curvas ($z \cong 5,5$) obteve-se valores de sensibilidade e especificidade da ordem de 90%.




Figura 3. Acima: registro de EEG de 1 segundo de duração e com espícula, em 600 ms. Abaixo: vetor de detalhes Coiflet1 reconstruído, nível de decomposição 2. A amplitude do pico relativo à espícula, em módulo, atingiu 8 desvios-padrão além da média ($z \cong 8$). **Figure 3.** Above: EEG register of one-second duration and with a spike, in 600 ms. Below: reconstructed detail vector Coiflet 1, scale 2. The amplitude of the spike-related peak, in module, achieved 8 standard deviations from mean ($z \cong 8$).




Figura 4. Acima: registro de EEG de 1 segundo de duração e com onda aguda, entre 400 e 600 ms. Abaixo: vetor de detalhes Coiflet1 reconstruído, nível de decomposição 3. A amplitude do pico relativo à espícula, em módulo, foi maior que 10 desvios-padrão além da média ($z > 10$). **Figure 4.** Above: EEG register of one-second duration and with a sharp wave, between 400 and 600 ms. Below: reconstructed detail vector Coiflet 1, scale 3. The amplitude of the spike-related peak, in module, was superior to 10 standard deviations from mean ($z > 10$).




Figura 5. Sinal de EEG com espículas – as de maior amplitude, marcadas com retângulos, foram detectadas pelo método. Já as marcadas com elipses, com pequenas energias e amplitudes e quase imperceptíveis não puderam ser detectadas por geraram pequenos valores de z . **Figure 5.** EEG signal with spikes – those with higher amplitudes, marked with rectangles, were detected by this method. On the other hand, those marked with ellipses, with lower energies and amplitudes and almost imperceptible could not be detected because generated short deviations.

Discussão e Conclusão

As funções wavelet diferem substancialmente entre si, em características tais como ordem dos filtros de decomposição, existência ou não de função inversa e de filtros de reconstrução, existência ou não de forma analítica, tamanho de suporte, momentos de decaimento, grau de oscilação, simetria em relação ao eixo y , ortogonalidade, possibilidade de implementação por algoritmo rápido, etc. Todas estas distinções obviamente fazem com que cada função seja mais ou menos adequada a um determinado tipo de análise. Além disto, a transformação pode ser vista como uma decomposição de um sinal utilizando-se uma família de funções e, como tal, funções de decomposição com morfologias semelhantes

aos sinais serão mais eficientes na representação, que funções morfologicamente distantes dos sinais a serem decompostos, pois estas últimas demandarão um número maior de coeficientes de aproximação.

Apesar disto, surpreende que poucos pesquisadores e autores das mais diversas áreas do conhecimento tenham explicitado suas metodologias de escolha da função wavelet aplicada e reconhecido que uma função wavelet possa ser adequada a uma aplicação, como por exemplo compressão de um tipo específico de dado e ao mesmo tempo, em um certo grau, não ser adequada à outra, como a filtragem de outro tipo de dado (Newbury *et al.*, 1998; Xiangqian e Lin, 1999; Christopoulou *et al.*, 2002).

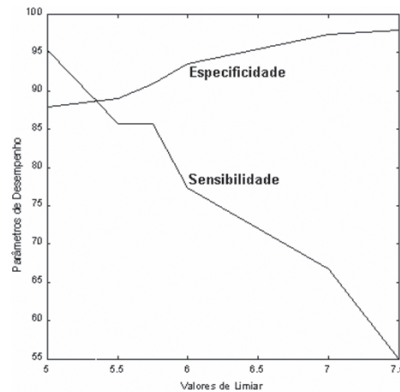


Figura 6. Desempenho do algoritmo de transformação wavelet em função do limiar arbitrado. O cruzamento entre as curvas de sensibilidade e especificidade ocorre em 88,7%, para o limiar de $z=5,34$ desvios, em relação à média.
Figure 6. Performance of wavelet transform-based algorithm, as function of arbitrated threshold. The crossover point between sensibility and specificity curves occurs at 88.7%, to a threshold of $z=5.34$ standard deviations from mean.

Neste trabalho utilizou-se um processo experimental e um teste estatístico para constatar-se que a função wavelet Coiflet1 é superior às outras analisadas, no que se refere à sua adequação como ferramenta de segmentação de espículas com relação à atividade de fundo e outros eventos, em sinais de EEG (Figura 7). Este resultado vem ao encontro do que já tinha sido constatado empiricamente no trabalho dos autores, em aplicações anteriores e ao que Düempelmann e Elger (1999) preconizaram, sem maiores detalhamentos.

Tão importante quanto isto foi a constatação de que funções como Biorotogonais 1.1, 1.3, 1.5 e 6.8, Daubechies 1, 6, 9 (Figura 7) e 19 e Symlet6 não foram capazes de ressaltar quaisquer eventos epileptogênicos, nos sinais de EEG reconstruídos, com relação à atividade de fundo (Fig. 7). Ou seja, se fossem utilizadas em aplicações, sem um estudo prévio, estas funções não trariam resultados favoráveis à análise wavelet.

Este procedimento representa apenas um passo para uma análise mais aprofundada da TW aplicada a EEG. Deve-se levar em conta o comportamento de outros eventos eletrográficos “normais” e “anormais”, passíveis de ocorrer no EEG (tal como os movimentos oculares, por exemplo) frente às diferentes funções wavelet. Também, idealmente, o número de experimentos estatísticos deve ser ampliado, com o aumento do número de amostras de EEG.

Outra abordagem interessante seria o desenvolvimento de uma função wavelet a partir do próprio padrão a ser reconhecido (no caso, o evento espícula), de forma a maximizar-se a correlação entre ambos, minimizando o erro de aproximação de um, pela outra (Tsatsanis e Giannakis, 1995; Moulin e Mihçak, 1998;

Vaidyanathan, 1998; Vaidyanathan e Kirac, 1998).

Em conclusão, o presente trabalho demonstra que apenas um limitado número de funções wavelets entre as aqui analisadas foram adequadas à tarefa de detecção de espículas no EEG humano e sugere uma metodologia simples e rápida que possa guiar a escolha de tais funções, de forma mais adequada à tarefa pretendida pelo usuário.

Este trabalho não tem a pretensão de se tornar referência na escolha de wavelets para uma determinada aplicação, mas sim sugerir a necessidade de metodologias mais apropriadas para realizar esta tarefa.

Agradecimentos

Os autores agradecem ao Montreal Neurological Institute, na pessoa do Prof. Dr. Jean Gotman, por todo o apoio fornecido e a CAPES, pelo financiamento deste projeto, através do programa PRODOC 2003.

Referências

- Argoud, F.I.M. (2001), “Contribuição à Automatização da Detecção e Análise de Eventos Epileptiformes em Eletroencefalograma”, Tese de Doutorado, Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, 185 p.
- Bruns, A. (2004), “Fourier-, Hilbert- and wavelet-based signal analysis: are they really different approaches?”, *Journal of Neuroscience Methods*, v. 137, p. 321-332.
- Christopoulou, E.B.; Skodras, A.N.; Georgakilas, A.A. (2002), “Time series analysis of sunspot oscillations using the wavelet transform”, *Digital Signal Processing*, 2002. *Proceedings. DSP 2002 - 14th IEEE International Conference on*, vol. 2, p. 893-896.
- Daubechies, I. (1992). “Ten lectures on wavelets”, 8a. ed., Filadélfia: SIAM, 357 p.

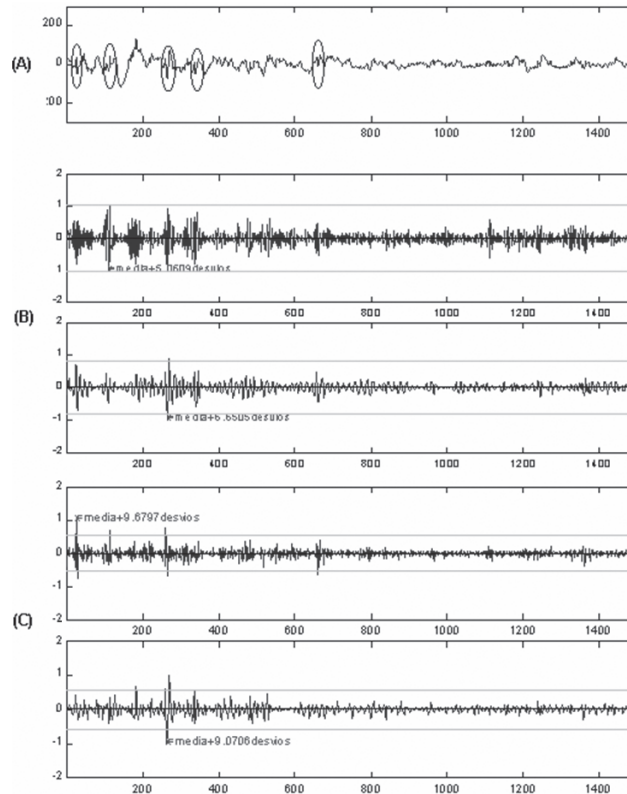


Figura 7. Em (A): sinal de EEG com espículas marcadas (com elipses), nos intervalos 0, 100, 200, 300 e 600 ms. Em (B): decomposição por wavelet de Daubechies9 e reconstrução dos vetores de detalhe 2 e 3 – notar que apenas a espícula no intervalo 200, do vetor de detalhes 3 causou ultrapassagem do limiar $z=5.34$. Em (C): decomposição por wavelet de Coiflet1 e reconstrução dos vetores de detalhe 2 e 3 – todos os eventos epileptogênicos geraram ultrapassagens do limiar, nos vetores de detalhe 2 (espículas em 0, 100, 200 e 600) e detalhe 3 (espículas em 100, 200 e 300). **Figure 7.** In (A): EEG signal with spikes marked (with ellipses), at intervals 0, 100, 200, 300 and 600 ms. In (B): wavelet decomposition by Daubechies 9 and reconstruction of detail components 2 and 3 – notice that only the spike at 200 ms, at detail vector 3, caused surpass on threshold $z=5.34$. In (C): wavelet decomposition by Coiflet 1 and reconstruction of detail components 2 and 3 – all epileptogenic events caused threshold crossing, in detail vectors 2 (spikes at 0, 100, 200 and 600 ms) and 3 (spikes at 100, 200 and 300 ms).

Düempelmann, M., Elger, C.E. (1999), "Visual and Automatic Investigation of Epileptiform Spikes in Intracranial EEG Recordings", *Epilepsia*, v. 40 n. 3, p. 275-285.

Fallon, A., Spada, C. (1997). "Detection and accommodation of Outliers in Normally Distributed Data Sets". Virginia Tech. Disponível em: <http://ewr.cce.vt.edu/environmental/teach/smprimer/outlier/outlier.html> [Acessado 03/05/05].

Fourth Epilepsy Teaching Weekend (1993) Lecture Notes. Ciba-Geigy Scientific Publications. Worcester College, Oxford, September 3rd, 1993.

Gopinath, R. A.; Odegard, J. E., Burrus, C. S. (1994). "Optimal Wavelet Representation of Signals and the Wavelet Sampling Theorem", *IEEE Trans. on Circuits and Systems*, v. 41, n. 4, p. 262-277.

Kalayci, T., Özdamar, O. (1995), "Wavelet preprocessing for automated neural network detection of EEG spikes", *IEEE Engineering in Medicine and Biology Society*, p. 160-166.

Khan, Y.U., Gotman, J. (2003), "Wavelet based automatic seizure detection in intracerebral electroencephalogram", *Clinical Neurophysiology*, v. 114, p. 898-908.

Mallat, S. (1998), "A Wavelet Tour of Signal Processing (Wavelet Analysis & Its Applications)", Los Angeles: Academic Press-Elsevier, 637 p.

Moulin, P.; Mihçak, M. K. (1998). "Theory and Design of Signal-Adapted FIR Paraunitary Filter Banks", *IEEE Transactions on Signal Processing*, v. 46, n. 4, p. 920-929.

Newbury, J.A.; Russell, C.T., Gedalin, M. (1998), "The ramp widths of high-Mach-number, quasi-perpendicular collisionless shocks", *Journal of Geophysical Research*, v. 103, n. 29, p. 581-593.

O'Donohoe, N.V. (1982), *Epilepsias na Infância*. São Paulo: Livraria Roca.

Schiff, S.J.; Aldoubri, A.; Unser, M., Satao, S. (1994), "Fast wavelet transformation of EEG", *Electroencephalography and Clinical Neurophysiology*, v. 91, p. 442-455.

Sheng, Y. (1996), "Wavelet Transform", in *The Transforms and*

- Applications Handbook*, Ed: A.D. Poularikas, 1ª Ed., Boca Raton: CRC Press and IEEE Press, p. 747-827.
- Speckmann, E. J.; Elger, C. E. (1993). "Introduction to the neurophysiological basis of the EEG and DC potentials". In: *Electroencephalography Basic Principles, Clinical Applications, and Related Fields*. 3.ed., Maryland: Williams and Wilkins, p. 15-26.
- Tsatsanis, M. K; Giannakis, G. B. (1995). "Principal Component Filter Banks for Optimal Multiresolution Analysis". *IEEE Transactions on Signal Processing*, v. 43, n. 8, p. 1766-1777.
- Unser, M. (1993). "On the Optimality of Ideal Filters for Pyramid and Wavelet Signal Approximation", *IEEE Transactions on Signal Processing*, v. 41, n. 12., p. 3591-3596.
- Vaidyanathan, P. P. (1998). "Theory of Optimal Orthonormal Subband Coders", In: *IEEE Transactions on Signal Processing*, v. 46, n. 6, p. 1528-1543.
- Vaidyanathan, P. P.; Kirac. A. (1998). "Results on Optimal Biorthogonal Filter Banks", In: *IEEE Transactions on Circuits and Systems: II*, v. 45, n. 8, p. 932-947.
- Wilson, S. B.; Emerson, R. (2002). "Spike Detection: a review and comparison of algorithms". *Clinical Neurophysiology*, v. 113, p. 1873-1881.
- Xiangqian, L.; Lin, Z. (1999), "Haar Wavelet and Its Application in Optimal Control of Linear Time-invariant Systems", *Tsinghua Science and Technology*, v. 4, n.1.

