

ANÁLISE ESPECTRAL DE SINAIS EEG UTILIZANDO MODELAGEM AUTO-REGRESSIVA

por

J.R. BOKEHI¹, D.M. SIMPSON² e A.F.C. INFANTOSI³

RESUMO -- Técnicas de processamento digital de sinais têm sido aplicadas ao EEG com vistas à identificação e extração de parâmetros clinicamente significantes para o diagnóstico e monitoração. Este trabalho objetiva investigar o emprego da modelagem auto-regressiva (AR) na estimação espectral de sinais EEG de indivíduos normais e portadores de deficiência renal, como exemplo típico de disfunção que se reflete em alterações das características do traçado eletroencefalográfico. A comparação das estimativas espectrais via transformada rápida de Fourier (FFT) e via modelagem AR (método de Burg / Equações Yule-Walker) foi efetuada para sinais simulados na faixa de frequência do ritmo alfa (8 - 12 Hz). Os resultados sugerem ser a modelagem AR (método de Burg) mais adequada, o que se confirma quando da aplicação a trechos de curta duração de sinais EEG. A ordem do modelo foi investigada, concluindo-se que as características do sinal EEG de indivíduos normais são respeitadas com ordem 10, confirmando estudos de outros autores. Entretanto, para o EEG de pacientes renais a ordem 40 foi considerada mais apropriada.

Palavras-chave: eletroencefalografia, estimação espectral, modelagem auto-regressiva.

INTRODUÇÃO

A análise clínica do EEG é geralmente baseada na inspeção visual de um conjunto de traçados, visando o reconhecimento de padrões, um processo subjetivo, sendo portanto altamente dependente da experiência e treinamento do eletroencefalografista. Apesar da utilização de parâmetros objetivos, tais como a frequência da atividade rítmica (por exemplo: ritmo alfa - na faixa 8 - 12 Hz), a ênfase metodológica ainda está na análise morfológica efetuada pelo especialista (Lopes da Silva, 1987a).

A análise quantitativa do EEG, através do uso de métodos computadorizados e técnicas de processamento de sinais, visa possibilitar a utilização mais eficiente e objetiva das informações usadas na análise convencional qualitativa, além de possibilitar a investigação da existência de outras informações clinicamente significantes, não óbvias à inspeção visual (Lopes da Silva,

¹Professor Assistente da Fundação de Ensino Superior de São João del-Rei - FUNREI e

^{2,3}Professores Adjuntos do Programa de Engenharia Biomédica - PEB - COPPE/UFRJ

Caixa Postal 68510 - CEP: 21945-910 - Rio de Janeiro, RJ - Brasil.

1987b). A metodologia quantitativa objetiva auxiliar o eletroencefalografista na análise e interpretação dos resultados, acelerar e aumentar a precisão do processo diagnóstico.

Para a análise quantitativa do EEG, geralmente se utiliza a análise espectral. A estimação espectral de sinais (aleatórios ou determinísticos) é frequentemente realizada por procedimentos baseados na transformada rápida de Fourier (FFT). No entanto, para certas aplicações a estimação espectral via modelo auto-regressivo (AR) é mais indicada, uma vez que a baseada na FFT possui limitações (Kay e Marple, 1981), tais como na resolução espectral.

Sinais EEG podem ser analisados por qualquer método capaz de evidenciar, dentro de um certo contexto, as características de interesse clínico destes sinais. Tais características podem variar consideravelmente em complexidade e duração; podendo ser curtas, como no caso de uma descarga ou pico epileptiforme (80 ms), ou longas, como no caso de um período caracterizado por um ritmo alfa estável. A utilização de métodos paramétricos na análise do sinal EEG permite a detecção de uma variedade de características. Tais métodos são assim denominados porque o sinal é descrito em termos de um conjunto de parâmetros. Segundo Lopes da Silva e Mars (1987), a justificativa da utilização destes métodos não deve ser buscada em uma similaridade formal entre os modelos matemáticos utilizados por estes e os modelos biofísicos que podem contribuir para a geração de alguns fenômenos do EEG. Um método paramétrico frequentemente utilizado é o modelo auto-regressivo (AR), assim denominado uma vez que relaciona o valor do sinal em um dado instante de tempo com seus valores em momentos anteriores (Lopes da Silva e Mars, 1987).

Na análise AR de um sinal, estima-se um filtro linear recursivo, que quando aplicado a um ruído branco resulta num sinal com espectro equivalente ao do sinal original. A figura 1 esquematiza esta operação, tendo como entrada do filtro linear um ruído branco (amostras não correlacionadas) e saída com as características desejadas. Com o emprego do modelo AR para estimação espectral a resolução espectral torna-se menos dependente da duração do sinal, do que com os métodos baseados na FFT.

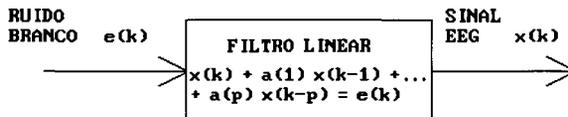


figura 1 - Representação esquemática de um filtro auto-regressivo (Lopes da Silva e Mars, 1987).

Segundo Jansen et alii (1981), a estimação espectral através do modelo AR é mais adequada que a FFT na detecção de mudanças rápidas e de curta duração no EEG. Isto se deve a dois fatores: (i) melhor resolução espectral que a FFT, requerendo uma menor quantidade de dados para estimativas aceitáveis; (ii) a possibilidade da obtenção de uma estimativa espectral de uma senóide quando os dados incluem menos que um ciclo da mesma, permitindo assim a estimação

espectral de ondas muito lentas, enquanto a FFT, por sua vez, necessita de segmentos contendo tipicamente cinco períodos do sinal para produzir estimadores espectrais confiáveis (Kitney et alii, 1986).

Uma vez que súbitas mudanças nas condições clínicas de pacientes portadores de doença renal são refletidas em pequenos deslocamentos do pico de máxima potência no espectro de frequências do EEG (Chotas et alii, 1979), e considerando-se os fatores anteriormente descritos, observa-se que a aplicação do modelo AR é bastante promissora na análise do EEG destes pacientes em particular.

Um dos maiores problemas na utilização do modelo AR é a escolha de sua ordem, a qual depende das características do sinal. Uma ordem elevada, pode resultar no aparecimento de detalhes espúrios no espectro, enquanto que uma ordem baixa implica um espectro suave possivelmente escondendo detalhes espectrais (Jansen et alii, 1981; Kitney et alii, 1986). Segundo Jansen et alii (1981), para sinais EEG de indivíduos normais, a ordem 10 conduz a um modelo mais realístico. Considerando que a morfologia dos sinais EEG de pacientes portadores de doença renal difere daquela de indivíduos normais por apresentar ritmos mais lentos que o alfa (Bowling e Bourne, 1978), a ordem proposta por Jansen et alii (1981) pode não ser a mais adequada. Assim, torna-se necessário investigar a ordem do modelo AR que respeite as características do sinal EEG destes pacientes.

ANÁLISE ESPECTRAL VIA MODELAGEM AUTO-REGRESSIVA

O modelo AR é definido por:

$$\begin{aligned}
 x(k) &= -a_1x(k-1) - a_2x(k-2) - \dots - a_px(k-p) + e(k) = \\
 &= -\sum_{n=1}^p a_nx(k-n) + e(k) \quad k = 1, 2, \dots, N
 \end{aligned} \tag{1}$$

onde $x(k)$ é o sinal auto-regressivo, $e(k)$ em geral é um ruído branco, a_1, a_2, \dots, a_p são coeficientes de um filtro recursivo e p a ordem do modelo. Quando o modelo AR é utilizado na estimação espectral, os coeficientes deste filtro são estimados para que o espectro de densidade de potência do sinal de saída do filtro se aproxime do espectro do sinal analisado. O modelo AR também pode ser utilizado para predição de sinal através de amostras anteriores, neste caso $e(k)$ representa o erro de predição do modelo.

A função de transferência do filtro, $H(z)$, obtida através da transformada Z da equação (1), onde $X(z)$ e $E(z)$ correspondem, respectivamente, à transformada Z de $x(k)$ e de $e(k)$, é dada por:

$$H(z) = \frac{X(z)}{E(z)} = \frac{1}{1 + \sum_{n=1}^p a_n z^{-n}} \quad (2)$$

O espectro de potência de saída, $S(f)$ (f em Hz), de um filtro linear com uma função de transferência dada, por (2), considerando como entrada um ruído branco de média zero e variância σ^2 , pode ser expresso por:

$$S(f) = \frac{\sigma^2 \Delta t}{\left| 1 + \sum_{n=1}^p a_n e^{-2\pi j f n \Delta t} \right|^2} \quad (3)$$

onde Δt é o intervalo de amostragem (Kay e Marple, 1981). O número máximo de picos no espectro depende do número de coeficientes e a localização destes picos é determinada pela posição dos polos complexos de (2) no plano Z (Jansen et alii, 1981). A frequência f é limitada pelo intervalo de Nyquist, $-1/(2 \Delta t) \leq f \leq 1/(2 \Delta t)$.

ESTIMADORES DOS COEFICIENTES AUTO-REGRESSIVOS

Vários métodos podem ser empregados na determinação de σ^2 e dos coeficientes a_n , como por exemplo, a aplicação das equações YULE-WALKER e o método de BURG. O modelo AR, via método de Burg ou via equações Yule-Walker, acarreta um tempo de processamento maior do que a FFT para analisar segmentos de mesmo tamanho.

Equações Yule-Walker

As equações Yule-Walker fornecem a relação entre os parâmetros AR e a função de autocorrelação (estimada ou conhecida) de $x(t)$. O conjunto de equações abaixo corresponde às equações Yule-Walker:

$$\begin{aligned} R_{xx}(0) + a_1 R_{xx}(-1) + \dots + a_p R_{xx}(-p) &= \sigma^2 \\ R_{xx}(1) + a_1 R_{xx}(0) + \dots + a_p R_{xx}(-(p-1)) &= 0 \\ R_{xx}(2) + a_1 R_{xx}(1) + \dots + a_p R_{xx}(-(p-2)) &= 0 \\ &\vdots \\ R_{xx}(p) + a_1 R_{xx}(p-1) + \dots + a_p R_{xx}(0) &= 0 \end{aligned}$$

e sabendo que $R_{XX}(-m) = R_{XX}(m)$, na forma matricial tem-se:

$$\begin{bmatrix} R_{XX}(0) & R_{XX}(1) & \dots & R_{XX}(p) \\ R_{XX}(1) & R_{XX}(0) & \dots & R_{XX}(p-1) \\ \vdots & \vdots & \ddots & \vdots \\ R_{XX}(p) & R_{XX}(p-1) & \dots & R_{XX}(0) \end{bmatrix} * \begin{bmatrix} 1 \\ a_1 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (4)$$

que é uma matriz Toeplitz simétrica (elementos ao longo das diagonais idênticos).

Tendo-se a função de autocorrelação ($R_{XX}(i)$, $i=0 \dots p-1$) os coeficientes AR podem ser calculados através da inversão da matriz de autocorrelação ou por métodos de solução de sistemas de equações simultâneas, tais como, eliminação de Gauss. Um método alternativo para se calcular os coeficientes das equações Yule-Walker e a variância, é o algoritmo recursivo de Levinson-Durbin. Este requer p^2 operações em oposição a p^3 requeridas pela eliminação de Gauss. Para o modelo de primeira ordem ($p=1$) pode-se definir o coeficiente e a variância por:

$$\begin{aligned} a_1 &= - R_{XX}(1) / R_{XX}(0) \\ \sigma^2 &= (1 - a_1^2) R_{XX}(0). \end{aligned} \quad (5)$$

Na modelagem de ordem superior ($p \geq 2$), o algoritmo recursivo para o cálculo dos coeficientes e da variância pode ser descrito por:

$$\begin{aligned} a_{m,m} &= - [R_{XX}(m) + \sum_{l=1}^{m-1} a_{m-1,l} R_{XX}(m-l)] / \sigma_{m-1}^2 \\ a_{m,i} &= a_{m-1,i} + a_{m,m} a_{m-1,m-i} \\ \sigma_m^2 &= (1 - a_{m,m}^2) \sigma_{m-1}^2 \end{aligned} \quad (6)$$

onde o primeiro subscrito indica a ordem do modelo.

Tais expressões podem ser consideradas como as equações gerais para cálculo dos coeficientes das equações Yule-Walker.

Para o cálculo dos coeficientes AR de um sinal finito, via equações Yule-Walker, é necessário "a priori" o conhecimento dos valores da autocorrelação. Como estes valores,

geralmente, não são conhecidos, torna-se necessário estimá-los através do trecho de sinal disponível:

$$\hat{R}_{xx}(m) = \frac{1}{N} \sum_{n=0}^{N-1-m} x(n+m)x(n), \quad m = 0, 1, \dots, p. \quad (7)$$

Assim, assume-se que os dados fora do intervalo de observação são iguais a zero (Jansen et alii, 1981), levando a erros nas estimativas de $R_{xx}(m)$ e conseqüentemente nas estimativas dos coeficientes.

Método de Burg

O algoritmo da máxima entropia para estimação espectral foi sugerido por John Burg em 1967 (Kay e Marple, 1981). Este algoritmo deve ser considerado como uma contribuição separada e distinta do conceito de entropia máxima de Burg apresentado no seu trabalho de 1975 (Marple, 1987). A estimação dos parâmetros AR pelo método de Burg é baseada em um critério de mínimos quadrados. Para ordem p , a média aritmética da potência do erro de predição linear direta e reversa é minimizada, com a restrição de que os parâmetros AR satisfaçam a recursão de Levinson

$$a_{m,i} = a_{m-1,i} + a_{m,m} a_{m-1,m-i} \quad (8)$$

para todas as ordens de 1 a p . Segundo Kay e Marple (1981), esta restrição é motivada para assegurar a estabilidade do filtro AR (polos dentro do círculo unitário). No trabalho de Andersen (1974), pode-se encontrar o desenvolvimento do algoritmo utilizado no método de Burg. As expressões implementadas neste estudo, além da (8), são as seguintes:

$$\sigma_0^2 = \frac{1}{N} \sum_{k=1}^N x(k)^2 \quad (9)$$

$$\begin{aligned} b_{1,k} &= x(k) \\ b'_{1,k} &= x(k+1) \end{aligned} \quad (k=1, \dots, N-1) \quad (10)$$

$$\begin{aligned} b_{m,k} &= b_{m-1,k} - a_{m-1,m-1} b'_{m-1,k} \\ b'_{m,k} &= b'_{m-1,k+1} - a_{m-1,m-1} b_{m-1,k+1} \end{aligned} \quad (k=1, \dots, N-m) \quad (11)$$

$$a_{m,m} = \frac{2 \sum_{k=1}^{N-m} b_{m,k} b'_{m,k}}{\sum_{k=1}^{N-m} (b_{m,k}^2 + b_{m,k}'^2)} \quad (12)$$

$$\sigma_m^2 = \sigma_{m-1}^2 (1 - a_{m,m}^2) \quad (13)$$

Uma vantagem deste método é que somente são utilizados os dados disponíveis, enquanto nas equações Yule-Walker, assume-se, no cálculo dos coeficientes da autocorrelação com estimador tendencioso, a hipótese de que os dados fora do intervalo de observação são iguais a zero (Jansen et alii, 1981).

ORDEM DO MODELO

Uma vez que a melhor escolha para a ordem do modelo (p) não é, geralmente, conhecida a priori, é necessário realizar experimentos com diversas ordens. A partir destes experimentos, a melhor ordem para o modelo pode ser estimada com base em critério pré-definido. Vários critérios têm sido introduzidos como bases objetivas para esta seleção. Um destes critérios, o erro final de predição (FPE), foi descrito por Akaike (1969), sendo definido por:

$$FPE(p) = \left(\frac{N + (p+1)}{N - (p+1)} \right) \sigma_p^2 \quad (14)$$

onde $p = 1, 2, \dots, L$; N é o número de amostras e σ_p^2 , a variância correspondente à ordem selecionada. A ordem ótima do modelo é o valor de p que corresponde ao menor valor de FPE. Esta função consiste de duas componentes: a variância (erro médio quadrático da estimação σ_p^2), que decresce com a ordem do modelo, e o termo restante, aumenta com a ordem, e se reflete no aumento da incerteza do valor estimado de σ_p^2 (Marple, 1987).

Deve ser enfatizado que a escolha da ordem do modelo é sempre um compromisso entre os erros randômicos e de tendência. Na prática, tende-se a escolher uma ordem relativamente baixa para economia nos cálculos, mas de um ajuste satisfatório.

Em 1974, Akaike sugeriu um segundo critério de seleção da ordem do modelo ótima, utilizando a abordagem de máxima verosimilhança, denominado AIC (Akaike information criterion). Segundo Kay e Marple (1981), assumindo-se que o processo é gaussiano, o AIC é definido por:

$$AIC(p) = \ln(\sigma_p^2) + (2p + 1)/N \quad (15)$$

Novamente, a ordem selecionada é aquela que minimiza o AIC. Kashyap (Kay e Marple, 1981) alega que o critério AIC é estatisticamente inconsistente em virtude da probabilidade de erro na escolha da ordem correta não tender a zero quando N tende a infinito. Porém, em experimentos, Schindwein e Evans (1990), obtiveram resultados contrários. Nota-se também que à medida que N tende para infinito AIC e FPE tornam-se equivalentes.

Existem outros critérios para a escolha da ordem ótima do modelo AR, mas nenhum é completamente aceito, especialmente para dados que não são perfeitamente auto-regressivos (Kay e Marple, 1981, Marple, 1987). A literatura cita ainda o uso de critérios subjetivos.

ESTIMATIVA ESPECTRAL VIA MODELO AR PARA SINAIS SIMULADOS

Nesta seção é realizado um estudo da estimativa espectral via modelo AR utilizando sinal simulado. O procedimento utilizado na estimação espectral através dos métodos AR e FFT durante esta simulação é o mesmo que será empregado na análise do sinal EEG.

Este estudo foi dividido em três etapas: (i) comparação da estimativa espectral via AR (equações de Yule-Walker e método de Burg) com aquela obtida via FFT, utilizando um sinal composto de senóides de 9,3 e 11 Hz, tendo ambas as senóides a mesma amplitude; (ii) idem ao item anterior, utilizando o sinal acrescido de um ruído branco gaussiano (figura 2), sendo a relação sinal/ruído (rms) igual a 5 (14 dB); (iii) estudo dos critérios de determinação da ordem ótima do modelo, FPE e AIC, utilizando os sinais dos itens anteriores.

Uma forma de se reduzir a variabilidade estatística da estimação espectral via FFT é a promediação de espectros (periodogramas) calculados de trechos consecutivos do sinal. Assim, em vez de aplicar a FFT ao sinal completo, aplica-se a segmentos de curta duração. A redução da variabilidade obtida por este procedimento implica na perda de resolução espectral. Adicionalmente, para se reduzir o efeito do espalhamento de energia pelas componentes espectrais vizinhas decorrente da segmentação, pode-se aplicar janelas "anti-leakage" (decaimento suave). Para se estimar o espectro via FFT, foi utilizado um trecho de sinal de 1024 pontos (8 segundos), segmentado em intervalos de 2 segundos, e, no caso de aplicação de janelas Hanning, promediados com defasagem de 1 segundo. A estimação via modelo AR foi realizada através das equações Yule-Walker e do método de Burg com ordem 10 para a primeira e segunda etapas do estudo e ordem 20 somente para a segunda.

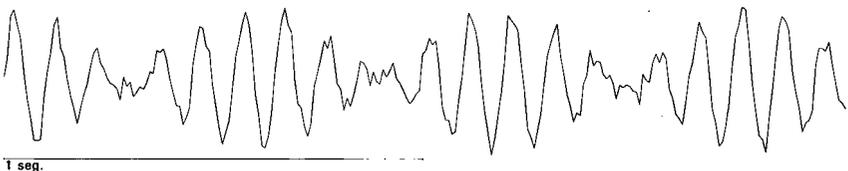


figura 2 - Sinal simulado composto de senóides de 9,3 e 11 Hz acrescido de ruído branco gaussiano.

A estimativa espectral via FFT do sinal sem ruído (figura 3a) mostra claramente 2 picos. Na frequência de 11 Hz (harmônico do sinal) o "leakage" é evidenciado com janela Hanning ("vazando" para 10,5 e 11,5 Hz) havendo atenuação significativa do valor de pico comparado com a janela retangular. Para a frequência de 9,3 Hz (múltiplo fracionário da resolução espectral) o "leakage" acontece com ambas as janelas. Para o sinal com ruído, os resultados foram (visualmente) quase idênticos.

Comparando as estimativas espectrais obtidas com o sinal sem ruído, pode-se notar que a obtida via modelo AR (figura 3b), método de Burg, apresentou a melhor resolução espectral com menos espalhamento de energia para outras frequências, de acordo com que é apresentado na literatura (Marple, 1987). Também apresentou resultado mais próximo do espectro verídico: impulsos nas frequências das oscilações. As amplitudes das componentes porém, não são iguais, o que talvez possa ser explicado da seguinte forma: os picos são extremamente agudos, como realçado na figura 4, com escala logarítmica, e assim o valor máximo é muito sensível a erros numéricos e ao posicionamento de amostras utilizada na apresentação gráfica. A amplitude destes picos é conseqüentemente pouco confiável. O espectro via modelo AR, equações Yule-Walker, (figura 3b) consegue também distinguir os picos nas frequências 9,3 e 11 Hz mas existe um "overlap" e a diferença entre as amplitudes não é tão grande.

Quando se tem um sinal com espectro mais complexo (ruidoso ou com várias componentes de frequência) os resultados mostram que a ordem do modelo deve aumentar para se poder identificar as senóides de 9,3 e 11 Hz simuladas. Por exemplo, no sinal sem ruído a ordem 10 já era satisfatória, mas quando se acrescentou o ruído branco, o espectro estimado (figura 5a) não conseguiu identificar as duas componentes de frequência deste sinal, sendo necessária uma ordem mais elevada. O espectro estimado com modelo de ordem 20 (figura 5b) conseguiu indicar as componentes de frequência quando utilizadas as equações Yule-Walker ou o método de Burg, sendo que neste último os picos são melhor destacados.

Na tabela 1 são apresentados os resultados da aplicação dos critérios de determinação da ordem ótima do modelo, FPE e AIC. A aplicação do teste de hipótese t emparelhado mostrou que, a um nível de significância de 5%, não existe diferença significativa entre estes critérios. A existência de mínimos locais nas funções FPE (figura 6) e AIC, sugere a necessidade de estudos mais apropriados para a aplicação destes métodos a sinais reais.

Tabela 1 - Apresenta as médias e desvios padrão resultantes do uso dos critérios FPE e AIC, para 20 trechos de 2 segundos, do sinal sem e com ruído.

	FPE	AIC
sinal s/ ruído	61,3 ± 2,1	61,9 ± 1,8
sinal c/ ruído	40,2 ± 7,2	40,0 ± 7,1

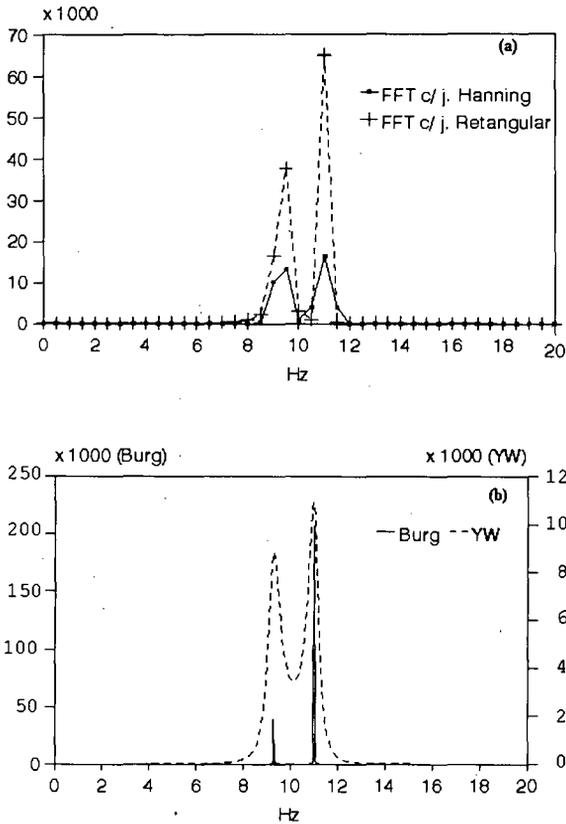


figura 3 - Estimativa espectral do sinal sem ruído: (a) via FFT com janela Hanning e com janela Retangular e (b) via modelagem AR - Método de Burg e Equações Yule-Walker (ordem 10).

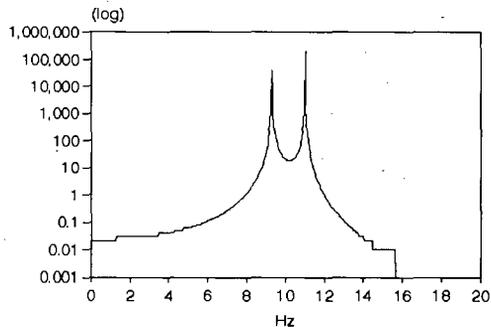


figura 4 - Estimativa espectral via modelagem AR - Método de Burg (ordem 10) com escala logarítmica do sinal sem ruído.

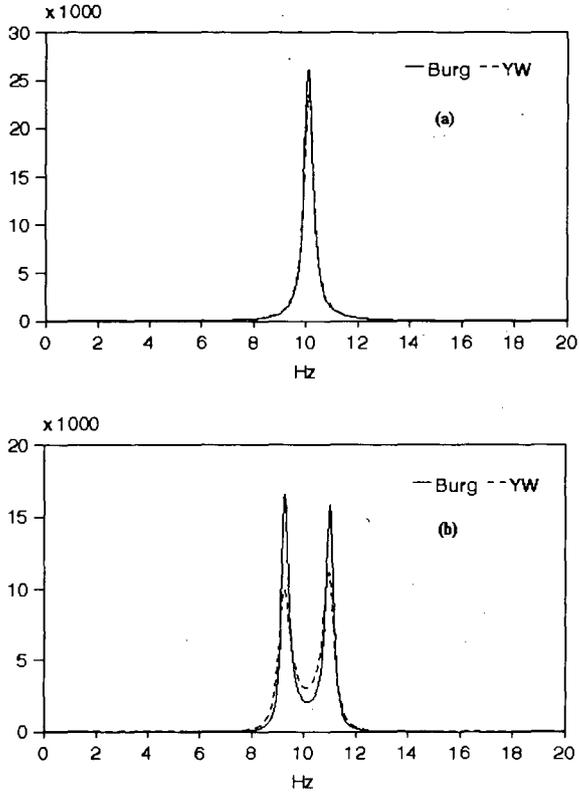


figura 5 - Estimativa espectral via modelagem AR - Método de Burg e Equações Yule-Walker do sinal com ruído branco gaussiano (fig. 2): (a) ordem 10 e (b) ordem 20.

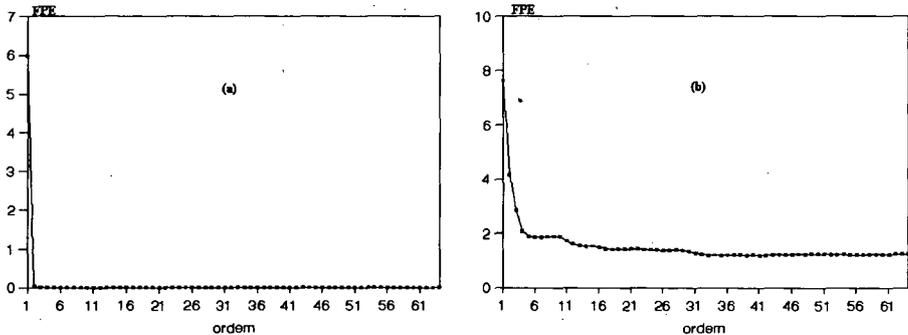


figura 6 - FPE para o sinal: (a) sem ruído e (b) com ruído branco gaussiano.

MODELAGEM AR APLICADA A SINAIS EEG

Aquisição de sinais

Para a captação dos sinais EEG utilizou-se somente o eletrodo O₂ com a referência no lobo da orelha do hemisfério homólogo ao da captação. Os sinais foram captados utilizando-se um eletroencefalógrafo Nihon Kohden (modelo EEG-4418A/E/K) de 18 canais, sendo também submetidos a filtragem (0,5 - 35 Hz) e amplificação para compatibilizá-los com o módulo de digitalização. Um conversor A/D de 12 bits, com faixa dinâmica de +/- 10V, foi utilizado na digitalização do sinal à taxa de 128 Hz. Os sinais foram então armazenados e monitorados em um microcomputador IBM/PC-AT compatível, com um disco rígido de 40 Mbytes. Na aquisição de sinais utilizou-se o protocolo de olhos fechados com ausência de esforço mental em indivíduos normais e em pacientes renais.

Comparação entre modelagem AR e FFT

O procedimento utilizado na estimação espectral através dos métodos AR e FFT nesta comparação é o mesmo empregado na análise do sinal simulado. A ordem utilizada na modelagem AR foi de 10, por ser a sugerida por Jansen et alii (1981) para sinais EEG.

Na figura 7a é apresentado um trecho de sinal EEG típico do protocolo experimental, derivação O₂, para o qual foi efetuada a análise espectral. A estimativa espectral via AR (figura 7c) apresenta morfologia mais suave e pico mais agudo do que a estimativa via FFT (figura 7b). Em ambos os casos, o pico se encontra localizado na faixa de atividade alfa o que é compatível com o protocolo experimental. As figuras 7d e 7e sugerem que o modelo AR permite melhor identificar (pico de maior amplitude e menor duração) o ritmo alfa presente no sinal EEG (trecho inicial de 1 segundo de duração) mostrado na figura 7a.

Ordem do modelo AR - EEG de pacientes renais

Para a determinação da ordem do modelo AR mais adequada para os sinais EEG de pacientes portadores de doenças renais, utilizou-se os critérios FPE e AIC, e análise qualitativa das estimativas espectrais de trechos de 8 e de 2 segundos destes sinais.

Na figura 8a é exibido um trecho de sinal EEG de um paciente portador de doença renal, mostrando uma lentificação comum a este tipo de paciente (Bowling e Bourne, 1978). Na estimativa espectral via FFT deste sinal (figura 8b) nota-se a existência de frequências na faixa delta e teta. Empregando-se modelagem AR com ordem 10 (figura 8c), estas características espectrais são praticamente suprimidas; por outro lado, utilizando-se ordem 40 (figura 8c), a presença dos ritmos delta e teta é novamente evidenciada. Tais resultados diferem daqueles encontrados por Jansen et alii (1981), e sua análise sugere que ordem superiores a 10 são mais adequadas para a modelagem AR de sinais EEG de pacientes renais.

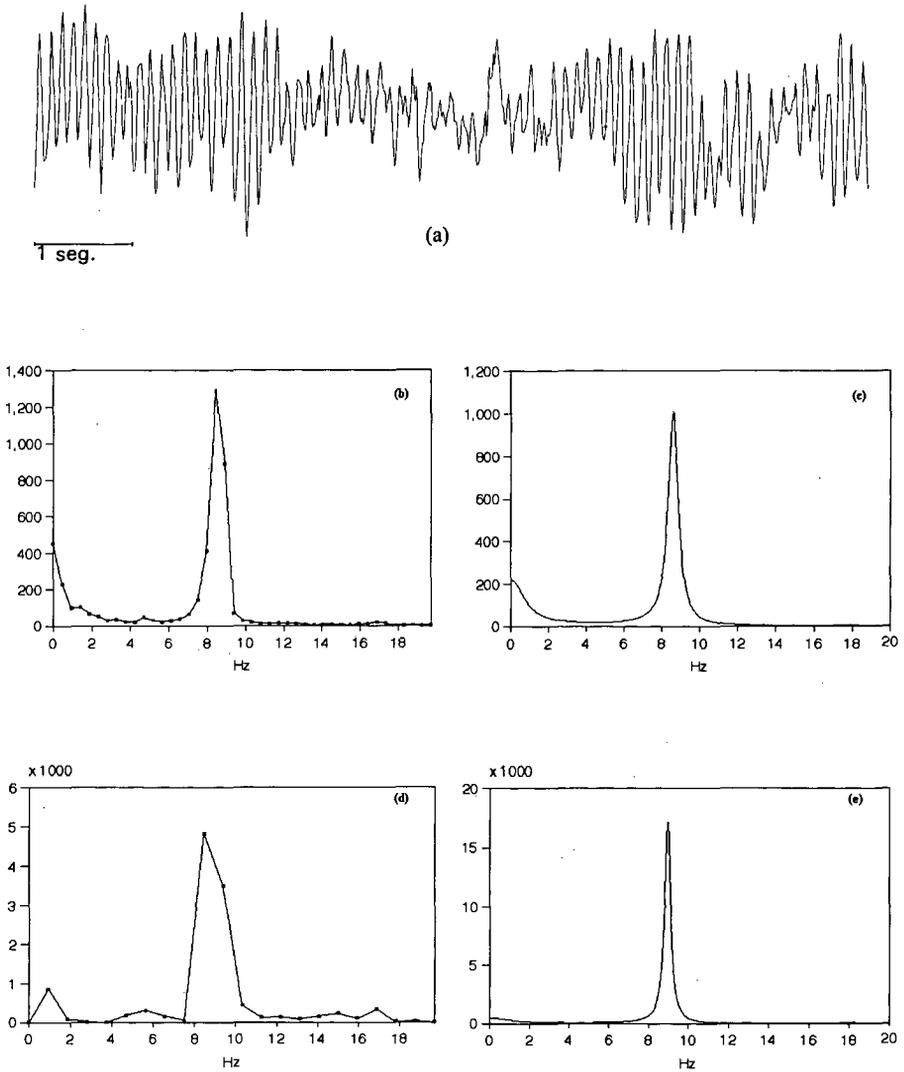
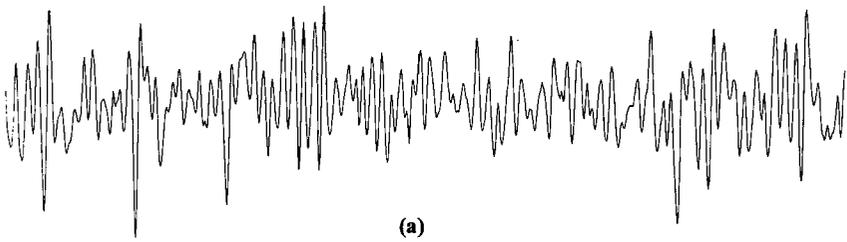


figura 7 - (a) Sinal EEG de indivíduo normal, canal O₂; Estimativa espectral: (b) via FFT de 8 seg. de sinal com promediação e aplicação de janelas Hanning; (c) via AR - Método de Burg de 8 seg. de sinal (ordem 10); (d) via FFT de 1 seg. de sinal e (e) via AR - Método de Burg (ordem 10) de 1 seg. de sinal.



1 seg.

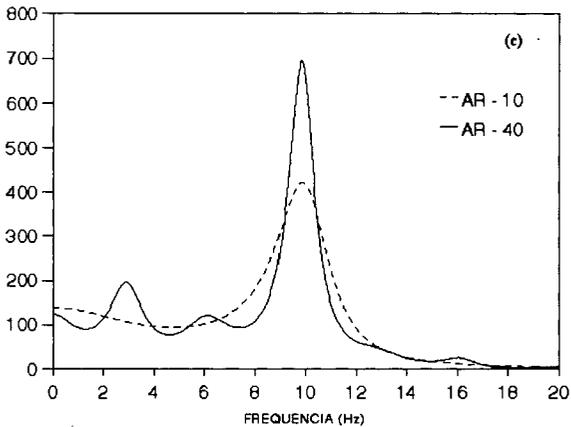
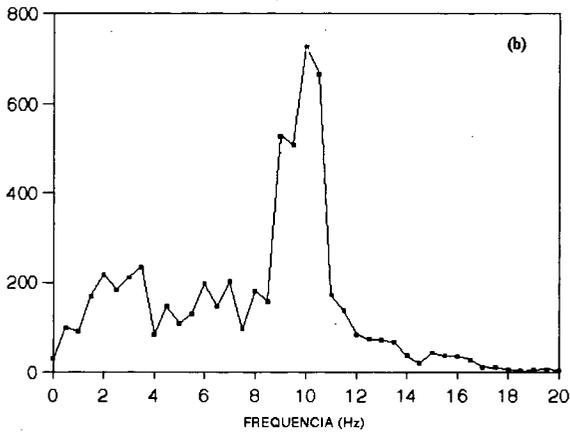


Figura 8 - (a) Sinal EEG de paciente portador de doença renal, canal O₂; Estimativa espectral: (b) via FFT e (c) via AR (método de Burg - ordem 10 e 40).

Os espectros AR para trechos de dois segundos de sinal EEG de paciente portador de doença renal antes da hemodiálise são apresentados na forma de "compressed spectral array" (CSA) para uma ordem de modelo igual a 10 e 40 (figuras 9a e 9b). Neste último, é evidenciado a presença de ritmos lentos, conforme apontado na literatura.

Utilizando-se os critérios FPE e AIC, para 20 trechos de 2 segundos, a média e o desvio padrão da ordem resultantes foram iguais a 33,1 e a 12,4, respectivamente. Resultado este não muito confiável, pois, como aconteceu nos sinais simulados, a existência de mínimos locais nas funções FPE e AIC afetam a escolha da ordem ótima do sinal.

Pode-se concluir, qualitativamente, que a ordem do modelo igual a 40 apresenta-se satisfatória para o estudo do sinais de pacientes portadores de doenças renais, sendo esta ordem superior que a recomendada para EEG de indivíduos normais. Os espectros estimados nos itens subseqüentes deste capítulo foram realizados através do uso da modelagem auto-regressiva, método de Burg, com ordem 40.

CONCLUSÃO

A comparação dos resultados obtidos na estimação espectral, via modelo AR e FFT, de sinais senoidais simulados e de EEG de indivíduos normais indica que a modelagem AR (método de Burg) é mais adequada à análise de trechos de curta duração de sinais não-estacionários como o EEG, pois conduz a uma melhor resolução espectral. A ordem 10, como citado na literatura, mostrou-se mais adequada ao estudo do EEG de indivíduos normais.

A utilização do modelo AR (método de Burg) para a análise espectral de sinais EEG de pacientes portadores de doença renal, também parece ser mais adequada que o emprego dos métodos baseados na FFT, pois permite a detecção de mudanças rápidas e de curta duração no EEG e conseqüentemente sua monitoração. Entretanto, a ordem do modelo depende das características do sinal, que nestes pacientes se manifesta através de um processo de lentificação (presença de ritmos delta e teta). A investigação desta ordem não confirma os resultados apresentados na literatura (ordem 10), sugerindo o emprego de ordens superiores. Para os pacientes estudados, a ordem 40 representa melhor as características do sinal.

AGRADECIMENTOS

Ao CNPQ, CAPES e FAPERJ, pelo apoio financeiro e ao Instituto Fernandes Figueira (FIOCRUZ - MS) pelo auxílio na aquisição dos sinais EEG.

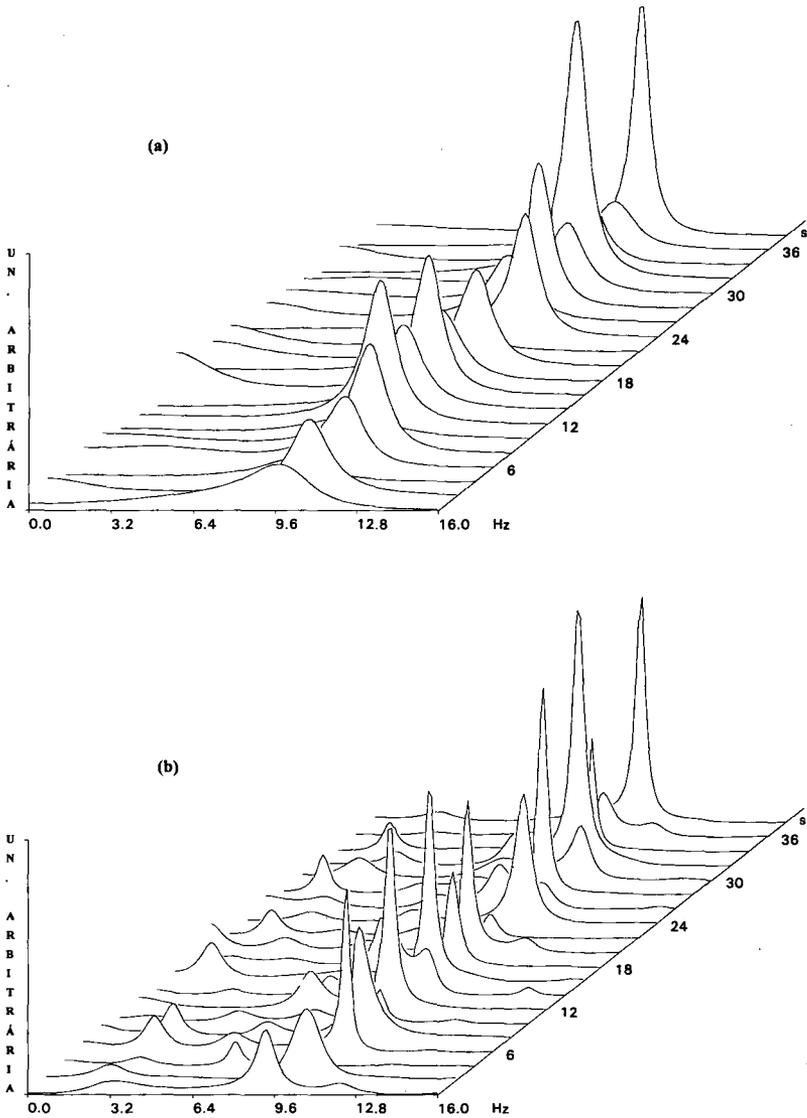


figura 9 - CSA de espectros AR de trechos de 2 segundos de sinal EEG de paciente portador de doença renal: (a) ordem 10 e (b) ordem 40.

REFERÊNCIAS BIBLIOGRÁFICAS

- AKAIKE, H.(1969), "Fiting Autoregressive Models for Prediction", Ann. Inst. Stat. Math., volume 21, páginas 243-247.
- AKAIKE, H. (1974), "A New Look at the Statistical Model Identification", in IEEE Trans. Autom. Contr., volume AC-19, páginas 716-723.
- ANDERSEN, N. (1974), "On the Calculation of Filter Coefficients for Maximum Entropy Spectral Analysis", Geophysics, volume 39, número 1, páginas 69-72.
- BOWLING, P. S. e BOURNE, J. R. (1978), "Discriminant Analysis of Electroencephalograms Recorded from Renal Patients", IEEE Transactions on Biomedical Engineering, volume BME-25, número 1, páginas 12-17.
- CHOTAS, H. G., BOURNE, J. R. e TESCHAN, P. E. (1979), "Heuristic Techniques in the Quantification of the Electroencephalogram in Renal Failure", Computers and Biomedical Research, volume 12, páginas 299 - 312.
- JANSEN, B. H., BOURNE, J. R. e WARD, J. W.(1981), "Autoregressive Estimation of Short Segment Spectra for Computerized EEG Analysis", IEEE Transactions on Biomedical Engineering, volume bme-28, número 9, páginas 630 - 638.
- KAY, S. M. e MARPLE, S. L. JR. (1981), "Spectrum Analysis - A Modern Perspective", Proceedings of the IEEE, volume 69, número 11, páginas 1380 - 1415.
- KITNEY, R. I., TALHAMI H. e GIDDENS, D. P. (1986), "The Analysis of Blood Velocity Measurements by Autoregressive Modelling", J. Theor. Biol., volume 120, páginas 419 - 442.
- LOPES DA SILVA, F. H. (1987a), " EEG Analysis: Theory and Praticce", in Electroencephalography: Basic Principles, Clinical Applications and Related Fields, editores E. NIEDERMEYER e F.H. LOPES DA SILVA, Baltimore, Urban & Schwarzenberg, páginas 871-897.
- LOPES DA SILVA, F. H. (1987b), " Computerized EEG Analysis: A Tutorial Overview", in A Textbook of Clinical Neurophysiology, editores A.M.HALLIDAY, S.R. BUTLER e R. PAUL, New York, John Wiley & Sons, páginas 61-101.
- LOPES DA SILVA, F. H. e MARS, N. J. I. (1987), "Parametric Methods in EEG Analysis", in Methods of Analysis of Brain Electrical and Magnetic Signals, EEG Handbook (revised series Volume1), páginas 243 - 260.
- MARPLE, S. L. JR. (1987), "Autoregressive Spectral Estimation: Block Data Algorithms", in Digital Spectral Analysis, New Jersey, Prentice-Hall, páginas 206-237.
- SCHLINDWEIN, F. S. e EVANS, D. H. (1990), "Selection of the Order of Autoregressive Models for Spectral Analysis of Doppler Ultrasound Signals", Ultrasound in Med. & Biol., volume 16, número 1, páginas 81-91.

SPECTRAL ANALYSIS OF EEG SIGNALS BY AUTOREGRESSIVE MODELING

by

J.R.BOKEHI , D.M.SIMPSON and A.F.C.INFANTOSI

ABSTRACT -- Digital signal processing techniques have been applied to EEG in order to identify and extract significant parameters for clinical diagnosis and monitoring. This work aims to investigate autoregressive modeling (AR) in spectral estimation of EEG signals from normal individuals and patients with renal problems, as a typical example of a dysfunction that is reflected in changes in EEG characteristics. The comparisons of spectral estimates obtained by Fast Fourier Transformer (FFT) and AR-modeling (Burg method and Yule-Walker equations) was carried out for simulated signals with frequency in the alpha band (8 - 12 Hz). The results suggest that AR-modeling (Burg method) is more adequate, which is confirmed in short EEG periods. The order of the model was investigated, concluding that the EEG characteristics of normal individuals are respected with order 10, in agreement with other authors' studies. However, for the EEG of patients with renal disturbances order 40 was considered more appropriate.

Key-words: eletroencefalography , spectral estimation, autoregressive modeling