

# Detecção de sonolência através de aproximação não-linear associada às transformadas wavelet e de Fourier

Tiago Silveira, Alice Kozakevicius, Cesar R. Rodrigues

Universidade Federal de Santa Maria – Grupo de Microeletrônica,  
97105-900, Cidade Universitária, Camobi, Santa Maria, RS  
E-mail: {[tiagodasilveira](mailto:tiagodasilveira@gmail.com), [alice.kozakevicius](mailto:alice.kozakevicius@gmail.com), [cesar.ufsm](mailto:cesar.ufsm@gmail.com)}@gmail.com

**Resumo:** Neste estudo, o método de melhor aproximação por  $m$  termos, *MAmT*, é utilizado na classificação de parâmetros de um sinal de EEG relacionados à sonolência. Esses parâmetros são obtidos através da: (i) série de Fourier do sinal de EEG, considerando as frequências correspondentes aos ritmos alfa e beta; (ii) série wavelet do sinal, considerando determinados níveis da transformada wavelet discreta de Daubechies. Os estados cognitivos são então classificados com base em um conjunto de pesos definidos através da *MAmT*. Quando aplicadas a sinais reais de EEG e comparadas com a classificação clínica, a metodologia utilizando *MAmT* e coeficientes wavelet apresentou uma taxa de acerto de 93% e efetividade 47% maior em relação à outra, utilizando coeficientes de Fourier. A associação da *MAmT* à transformada wavelet de um sinal de EEG mostra-se, portanto, um método bastante efetivo e de baixa complexidade para a detecção de sonolência.

**Palavras-chave:** Detecção de sonolência, melhor aproximação por  $m$ -termos, transformada wavelet, transformada de Fourier

## 1 Introdução

A Administração Nacional de Segurança no Trânsito (*National Highway Traffic Safety Administration*, Estados Unidos), estima que 100.000 ocorrências policiais envolvendo acidentes de trânsito sejam registradas, por ano, decorrente de sonolência em motoristas. Estudos indicam que até 30% dos acidentes de trânsito envolvendo vítimas fatais são ocasionados por motoristas sonolentos [1].

A sonolência pode então ser considerada um problema de saúde pública [2] e justifica o interesse da indústria automobilística em desenvolver dispositivos de bordo capazes de detectar e mitigar sinais de sonolência em condutores. Com base nestas premissas, este estudo visa discutir a detecção de sonolência através da aplicação da melhor aproximação por  $m$ -termos (*MAmT*) na análise de um sinal de eletroencefalografia (EEG) utilizando as transformadas de Fourier e wavelet.

Do ponto de vista neurofisiológico, a sonolência pode ser definida como a transição entre a vigília e o sono, caracterizada pelo decréscimo da atenção e por movimentos lentos. Este processo tem início com a ativação e inibição simultânea de grupos de neurônios em diferentes áreas do cérebro. Por ser rítmico e sincronizado, pode ser analisado através da variação da amplitude da corrente elétrica no cérebro, detectável através da eletroencefalografia (EEG). A sonolência é então caracterizada por (i) decréscimo de atividade no ritmo beta ([13-30]Hz); (ii) aumento e subsequente redução de atividade no ritmo alfa ([8-13]Hz) e (iii) aumento de atividade no ritmo teta ([4-8]Hz) [3].

Desta perspectiva, a sonolência é considerada um padrão a ser reconhecido nos sinais cerebrais: a transformada de Fourier ou a transformada wavelet [3] são comumente utilizadas para

a extração de características, enquanto a distância de Mahalanobis [4], análise de componentes independentes [5] ou redes neurais artificiais podem ser utilizadas como classificadores [6].

Neste estudo, o pré-processamento consiste na seleção de épocas de 30s do sinal; em seguida, as características do sinal EEG são extraídas por duas abordagens, combinando-se a MAmT à (i) expansão em série de Fourier e à (ii) expansão em série wavelet, conforme apresentado na Seção 2. Os algoritmos para classificação destas características e consequente detecção da sonolência estão definidos na Seção 3. Por fim, os resultados obtidos são discutidos na Seção 4 e as conclusões são apresentadas na Seção 5.

## 2 Extração de características do sinal EEG

### 2.1 Transformada breve de Fourier (TBF)

A transformada breve de Fourier (TBF), também denominada *Short-Time Fourier Transform* [14], é uma extensão da transformada de Fourier aplicável a sinais não-estacionários ou para obtenção da localização tempo-frequência. Consiste em multiplicar cada senoide da base da transformada por uma função janela  $w(t)$  (função não-nula em apenas um intervalo limitado de tempo), obtendo uma nova base cujas funções são definidas pelos parâmetros  $\omega$  (frequência) e  $\tau$  (posição):

$$G = \{w(t - \tau)e^{i\omega t}\}_{\omega \in \mathbb{R}, \tau \in \mathbb{Z}} \quad (1)$$

A TBF é dada pelo cálculo dos coeficientes  $F(\tau, \omega)$ , determinados pela relação:

$$F(\tau, \omega) = \int_{-\infty}^{\infty} f(t)\overline{w(t - \tau)e^{i\omega t}}dt. \quad (2)$$

A escolha do formato e comprimento da janela tem um forte impacto na decomposição do sinal. O primeiro varia de acordo com a função escolhida para gerá-la e determina sua capacidade de resolução em frequência. Já o comprimento define o intervalo da janela e, portanto, sua resolução temporal.

Uma vez definidos a forma e o comprimento da janela da TBF, estes serão fixos para toda a transformada. A alteração desses parâmetros resulta em bases de funções diferentes e, portanto, em transformadas diferentes [13]. Neste estudo, a TBF foi aplicada utilizando a janela de Hamming ( $w_h(t) = 0.54 - 0.46 \cos(2\pi t/M)$ , sendo  $M$  o número de pontos) com 512 pontos e sobreposição de 500 pontos. A janela de Hamming foi escolhida pela simplicidade de implementação e por oferecer resoluções de tempo e frequência adequadas aos sinais deste estudo. Para a análise do sinal de EEG, calcula-se o quadrado do módulo da TBF (espectrograma) para uma determinada frequência  $\omega$ , correspondente ao ritmo de interesse.

### 2.2 Transformada wavelet discreta (TWD)

A transformada wavelet consiste em determinar os coeficientes da expansão em série wavelet do sinal  $f(t)$ , dados pela correlação, isto é, o produto interno, entre  $f(t)$  e a função wavelet de análise  $\psi(t)$ . Neste estudo, a transformada wavelet discreta (TWD) é calculada através de bancos de filtros associados à família de wavelets ortonormais de Daubechies com dois momentos nulos (DB2), implementados através da transformada wavelet rápida [7]. Para o sinal  $f(t)$ , a expansão em série wavelet através da TWD é dada por:

$$f(t) = \sum_{l=0}^{2^{J_0}-1} c_{J_0,l} \phi_{J_0,l}(t) + \sum_{j=J_0}^{J-1} \sum_{l=0}^{2^j-1} d_{j,l} \psi_{j,l}(t). \quad (3)$$

A seguinte notação é utilizada:  $J_0$  é o nível mais grosseiro da TWD, no qual a transformada wavelet inversa (TWI) tem início;  $J$  é o nível mais refinado, com  $2^J$  elementos, equivalente às amostras de entrada do sinal. Os níveis da TWD são ordenados de maneira que  $J_0 \leq j \leq J$ .

Ao se aplicar a TWD à  $f(t)$ , obtém-se o conjunto de coeficientes  $\bar{f} = \{C_{J_0}, D_{J_0}, D_{J_0+1}, \dots, D_{J-1}\}$ . Cada nível  $j$  possui  $2^j$  elementos,  $j = J_0, \dots, J - 1$ , e portanto o número total de coeficientes wavelet para toda a decomposição é  $N = 2^{J-1} - 2^{J_0}$ . O subconjunto  $C_{J_0}$  contém os coeficientes de escala  $c_{J_0,l}$  para o nível  $J_0$  e posições  $l = 0, 1, \dots, 2^{J_0} - 1$ . O subconjunto  $D_j$  contém os coeficientes wavelet  $d_{j,l}$  para o nível  $j$  e posições  $l = 0, 1, \dots, 2^j - 1$ .

Uma vez que a sonolência é caracterizada através de ritmos cerebrais, é fundamental estabelecer uma relação entre as escalas dos níveis da TWD e as frequências relacionadas ao fenômeno de sonolência. Considerando-se que cada wavelet  $\psi(t)$  possui uma frequência central  $f_c$  – correspondente à frequência da senoide que melhor representa a forma de onda de  $\psi(t)$  – a relação entre escala e frequência pode ser dada através de pseudo-frequências  $f_\alpha$ , determinadas pela razão entre  $f_c$  e o produto  $\alpha T_s$  [8].

A Tabela 1 relaciona as escalas dos diferentes níveis da TWD aos principais ritmos cerebrais através de suas pseudo-frequências. Estes valores foram calculados utilizando-se  $T_s = 0.01s$ , equivalente ao período de amostragem do sinal analisado.

Tabela 1: Relação entre os ritmos cerebrais e os níveis da TWD (DB2,  $f_c = 0.6667$ ,  $f_s = 100Hz$ ).

Ritmo cerebral	Nível da TWD (J=12)	$f_\alpha$ [Hz]
Beta [13-30Hz]	$j_\beta = j_{11}$	33.34
Alpha [8-13Hz]	$j_\alpha = j_9$	8.33
Theta [4-8Hz]	$j_\theta < j_8$	4.16

### 2.3 Melhor Aproximação por m-Termos (MAMT)

Métodos não-lineares têm diversas aplicações no processamento de imagens, compactação de sinais, estimação estatística e resolução de equações diferenciais parciais [10, 11]. A MAMT, um método não-linear, tem como objetivo expressar um conjunto de dados de entrada através de um subconjunto com menor quantidade de elementos, de tal forma que haja a menor perda de informação possível [12].

Seja  $f(t)$  um sinal expresso como combinação linear de uma base de funções  $u_1(t), u_2(t), \dots, u_n(t)$ , onde  $c_1, \dots, c_n$  representam os respectivos coeficientes. Deseja-se obter uma aproximação  $p(t)$  da função  $f(t)$  através de uma base reduzida de funções  $\tilde{u}_1(t), \dots, \tilde{u}_m(t)$ , com coeficientes  $\tilde{c}_1, \dots, \tilde{c}_m$ , de modo que  $m < n$  e que o erro  $\|p(t) - f(t)\|$  entre a função aproximada e a função original seja aceitável:

$$f(t) = \sum_{i=1}^n c_i u_i(t), \quad p(t) = \sum_{i=1}^m \tilde{c}_i \tilde{u}_i(t). \tag{4}$$

Neste estudo, a propriedade da MAMT de representar um sinal através de uma base reduzida de funções é utilizada de maneira que esta aproximação caracterize a presença de sonolência e permita a classificação do sinal. Os algoritmos desenvolvidos associando a MAMT à transformada de Fourier e à transformada wavelet são explorados na seção seguinte.

## 3 Algoritmos de classificação

### 3.1 MAMT após TBF

Dado o sinal  $f(t)$ , após a aplicação da TBF obtém-se o conjunto de coeficientes  $\hat{f}(t) = \{F_{4Hz}, F_{5Hz}, \dots, F_{30Hz}\}$ . A MAMT seleciona os primeiros  $m$  coeficientes de maior magnitude do conjunto de tamanho  $N$ , com  $m < N$ . Em seguida, calcula-se o peso alfa  $P_\alpha$  através da quantidade de coeficientes significativos na faixa de 8 a 13Hz. O processo empregado está detalhado no algoritmo a seguir:

**Require:** Sinal  $f(t)$  com  $2^J$  amostras; valor de  $m$  coeficientes significativos.

**Ensure:** Estado **ALERTA** ou **SONOLÊNCIA**.

- 1:  $TBF(f) \rightarrow \hat{f}$
- 2: MAmT em  $\hat{f} \rightarrow \hat{p}$
- 3: De  $\hat{p}$ , calcula  $P_\alpha$
- 4: **if**  $P_\alpha > \lambda_\alpha$  **then**
- 5: Estado  $\leftarrow$  SONOLÊNCIA
- 6: **else**
- 7: Estado  $\leftarrow$  ALERTA
- 8: **end if**

O valor de  $\lambda_\alpha$  é determinado empiricamente através de uma base de treinamento, conforme detalhado na Seção 4. Os demais ritmos cerebrais não são considerados no processo por não serem relevantes na distinção entre os estados de alerta e sonolência através desta metodologia.

### 3.2 MAmT após TWD

Dado um conjunto de coeficientes  $\bar{f} = \{C_{J_0}, D_{J_0}, D_{J_0+1}, \dots, D_{J-1}\}$  proveniente da expansão em série wavelet do sinal  $f(t)$ , a MAmT seleciona apenas os primeiros  $m$  coeficientes wavelet de maior magnitude, com  $m < N$ , onde  $N$  representa o total de coeficientes deste conjunto.

Considerando-se que cada nível  $j$  da TWD possui  $2^j$  coeficientes, os coeficientes significativos dos níveis correspondentes aos ritmos alfa e beta (ver Tabela 1) são ponderados através do peso alfa ( $P_\alpha$ ) e peso beta ( $P_\beta$ ):

$$P_\alpha = \frac{m_{j_\alpha}}{2^{j_\alpha}} * 100, \quad P_\beta = \frac{m_{j_\beta}}{2^{j_\beta}} * 100, \quad (5)$$

Assim, o seguinte algoritmo associando a MAmT à TWD é utilizado para a detecção de sonolência, sendo os valores de  $\lambda_\alpha$  e  $\lambda_\beta$  determinados empiricamente através da base de treinamento definida na Seção 4.

**Require:** Sinal  $f(t)$  com  $2^J$  amostras; valor de  $m$  coeficientes significativos.

**Ensure:** Estado **ALERTA** ou **SONOLÊNCIA**.

- 1:  $TWD(f) \rightarrow \bar{f}$
- 2: MAmT em  $\bar{f} \rightarrow \bar{p}$
- 3: De  $\bar{p}$ , calcula  $P_\alpha$
- 4: De  $\bar{p}$ , calcula  $P_\beta$
- 5: **if**  $P_\alpha > \lambda_\alpha$  **then**
- 6: Calcula  $\lambda_\beta(P_\alpha)$
- 7: **if**  $P_\beta < \lambda_\beta$  **then**
- 8: Estado  $\leftarrow$  SONOLÊNCIA
- 9: **else**
- 10: Estado  $\leftarrow$  ALERTA
- 11: **end if**
- 12: **else**
- 13: Estado  $\leftarrow$  ALERTA
- 14: **end if**

## 4 Resultados e discussões

Os algoritmos apresentados na Seção 3 foram aplicados primeiramente a uma base de treinamento constituída por 200 épocas de 30s, provenientes da base de dados *Physionet Sleep Database* [15]. A Figura 1 mostra os resultados da classificação de acordo com o hipnograma clínico.

Através destes resultados foram definidos os limiares para o MAmT aplicado à TBF (Fig.1(a),  $\lambda_\alpha = 14.5$ ) e para o MAmT aplicado à TWD (Fig.1(b),  $\lambda_\alpha = 25$  e  $\lambda_\beta = 0.429P_\alpha - 8.714$ ).




Figura 1: Resultado da classificação utilizando MAmT e (a) TBF; (b) TWD.

Definidos os parâmetros de classificação, os algoritmos foram então aplicados a 32 sinais de uma base de testes com 4 pacientes distintos [15], obtidos através do canal  $F_{pz}$  (eletrodo posicionado na região pré-frontal do paciente). Cada sinal selecionado contém 10 minutos de duração, amostrados a uma frequência  $f_s = 100Hz$ . Os sinais foram selecionados de maneira a demonstrar os seguintes estados cognitivos, baseados no hipnograma clínico: (W) alerta, com os olhos abertos e desenvolvendo atividades de concentração; (D) sonolência, indivíduo relaxado e de olhos fechados, havendo predominância do ritmo alfa no EEG; e (N1) primeiro estágio do sono, de acordo com a escala de classificação R&K [3].

A Figura 2 mostra o resultado dos algoritmos aplicados à base de teste: o MAmT associado à TBF (Fig.2(a)) mostra-se eficiente na detecção de sonolência apenas nos pacientes 01 e 04, cuja sonolência é de característica alfa (D), chegando a taxas de acerto nula naqueles pacientes com sonolência (N1); o MAmT associado à TWD mostra-se eficiente tanto com sonolência (D) quanto (N1), obtendo taxas de acerto sempre maiores de 72%.

Dentre os motivos para o método associado à TWD ser mais eficiente, destaca-se a maior resolução temporal da TWD. Ainda, a utilização pela TBF de sobreposição de pontos resulta na replicação de um determinado evento ao longo do tempo, resultando que um coeficiente significativo tenha sua vizinhança também significativa.




Figura 2: Taxas de acerto na detecção de sonolência: (a) MAmT - TBF; (b) MAmT - TWD.

## 5 Conclusões

Através da MAmT é possível aproximar a expansão em série de um sinal assumindo-se um determinado erro. É possível, com esta técnica, identificar a ocorrência dos ritmos cerebrais relacionados à sonolência (alfa e beta) tanto através da expansão em série wavelet quanto da expansão em série de Fourier.

Qualitativamente, o algoritmo MAmT associado à TWD foi capaz de identificar tanto o estágio de sonolência relacionado ao ritmo alfa quanto o estágio inicial do sono, com predominância do ritmo teta e redução do ritmo beta. Já o algoritmo MAmT associado à TBF mostrou resultados satisfatórios apenas na identificação da sonolência caracterizada pelo ritmo alfa.

De acordo com os resultados experimentais, a associação da MAmT à transformada wavelet possibilitou uma taxa de acerto média de 93%, enquanto a associação da técnica à TBF possibilitou uma taxa de acerto média de 46%. Assim, a MAmT associada à TWD destaca-se como um método efetivo e de baixa complexidade na detecção de sonolência.

## Referências

- [1] R.R. JOHNSON et al. *Drowsiness/alertness algorithm using synchronized EEG and cognitive performance to individualize a generalized model*. Biological Psychology, 2011.
- [2] P.S. FOURNIER et al. *Fatigue management by truck drivers in real life situations: some suggestions to improve training*. Work Reading Mass, 2007.
- [3] Blinowska, K. & Durka, P. *Electroencephalography (EEG)*. Wiley Encyclopedia of Biomedical Engineering, John Wiley & Sons, 2006.
- [4] Lin, C. T. et al. *A real-time wireless brain-computer interface system for drowsiness detection*. IEEE Transactions on Biomedical Circuits and Systems, 2010.
- [5] Lin, C. T. et al. *EEG-Based drowsiness estimation for safety driving using independent component analysis*. IEEE Transactions on Circuits and Systems, 2005.
- [6] Subasi, A. *Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients*. Expert Systems with Applications, 2005.
- [7] O.M. NIELSEN, *Wavelets in Scientific Computing*. Technical University of Denmark. Denmark, 1998.
- [8] M. MISITI et al, *Wavelet Toolbox 4 User's Guide*. Matlab. 2010.
- [9] G. STRANG, T. NGUYEN. *Wavelets and Filter Banks*. Wellesley-Cambridge, 1996.
- [10] V.N. TEMLYAKOV. *Nonlinear methods of approximation*. Foundations of Computational Mathematics, 2003.
- [11] R.A. DEVORE. *Nonlinear approximation*. Cambridge University Press, 1998.
- [12] E.J. STOLLNITZ, T.D. DEROSE and D.H. SALESIN, *Wavelets for Computer Graphics: A Primer, Part 1*. IEEE Computer Graphics and Applications, 1995.
- [13] A. ROCHA et al. *Processamento de Sinais Biológicos*. Informática em Saúde. Taguatinga: Universa, 2008.
- [14] S. SMITH. *Digital Signal Processing: A Practical Guide for Engineers and Scientists*. Newnes, 2002.
- [15] *The sleep EDF database*. PhysioNet. Netherlands, 1992.