

ANÁLISE MONOESPECTRAL DE IMAGENS FUNCIONAIS DE RESSONÂNCIA MAGNÉTICA UTILIZANDO MAPAS AUTO-ORGANIZADOS DE KOHONEN

WELLINGTON P. DOS SANTOS*, RICARDO E. DE SOUZA†, ASCENDINO F. D. E SILVA‡, ANA CRISTINA T. C. DE ALBUQUERQUE§, MARIA LÚCIA B. SIMAS§

**Departamento de Sistemas Computacionais, Escola Politécnica de Pernambuco
Universidade de Pernambuco
50720-001, Recife, Pernambuco, Brasil*

†*Departamento de Física, Universidade Federal de Pernambuco
50670-901, Recife, Pernambuco, Brasil*

‡*Departamento de Eletrônica e Sistemas, Universidade Federal de Pernambuco
50740-530, Recife, Pernambuco, Brasil*

§*Laboratório de Percepção Visual, Departamento de Psicologia
Universidade Federal de Pernambuco
50670-901, Recife, Pernambuco, Brasil*

Emails: wellington@dsc.upe.br, res@df.ufpe.br, afd@ufpe.br, actaunay@gmail.com, maria.simas@pq.cnpq.br

Abstract— One of the major challenges at the field of cognitive sciences is mapping the regions of the brain responsible for the motor and behavioral functions. The acquisition of functional magnetic resonance images is an important non-invasive technique to study the neural activity in the human brain. This work presents a new approach for the detection of activated brain regions: the composition and analysis of synthetic multi and monospectral images using statistical methods and proposing non-parametrical methods based on Kohonen self-organized networks.

Keywords— Functional magnetic resonance imaging, Detection of neural activity, Pattern recognition, Self-organized Kohonen maps.

Resumo— Um dos maiores desafios atuais no campo das ciências cognitivas é mapear as regiões do cérebro responsáveis pelas funções motoras e comportamentais. A aquisição de imagens funcionais de ressonância magnética é uma técnica não-invasiva fundamental para o estudo da atividade neural do cérebro humano. Este trabalho apresenta uma nova abordagem para a detecção de regiões cerebrais ativadas: a composição e análise de imagens multiespectrais e monoespectrais sintéticas utilizando métodos estatísticos e propondo métodos não-paramétricos baseados em mapas auto-organizados de Kohonen.

Keywords— Ressonância magnética funcional, Detecção de atividade neural, Reconhecimento de padrões, Mapas auto-organizados de Kohonen.

1 Introdução

Um dos maiores desafios no campo das ciências cognitivas é mapear as regiões do cérebro responsáveis pelas funções motoras e comportamentais. A aquisição de Imagens de Ressonância Magnética Funcional (*functional Magnetic Resonance Imaging*, fMRI), tal como a Tomografia por Emissão de Pósitrons (*Positron Emission Tomography*, PET) e a Tomografia Computadorizada por Emissão de Fóton Único (*Single Photon Emission Computerized Tomography*, SPECT), é uma técnica não-invasiva fundamental para o estudo da atividade neural do cérebro humano.

As imagens fMRI são adquiridas utilizando a seqüência Eco-Planar de Aquisição de Imagens (*Echo Planar Imaging sequence*, EPI) e a técnica BOLD, que exploram tanto a propriedade diamagnética da oxi-hemoglobina quanto a propriedade paramagnética da desoxi-hemoglobina como um mecanismo de contraste natural (Giacomantone, 2005), elevando o sinal nos vo-

xels tipicamente de 1% a 5% em tomógrafos de 1.5 T (Malinen et al., 2007; Bartsch et al., 2007; Haacke et al., 1999; Maldjian et al., 1999), produzindo artefatos na imagem resultante (Haacke et al., 1999).

Um exame de fMRI consiste em três etapas de aquisição: aquisição *anatômica*, *sob estímulo* e *sem estímulo* (Bandettini, 2007). Durante a primeira etapa são adquiridas imagens anatômicas de alta resolução sobre as quais é montado o *mapa de ativação*. Nas etapas de aquisição sob estímulo e sem estímulo são adquiridas todas as imagens para reconstrução do volume cerebral, sendo que, na aquisição sob estímulo, o voluntário está sob o experimento de interesse, enquanto na aquisição sem estímulo as imagens são adquiridas quando o voluntário se encontra em repouso. As imagens são adquiridas em quantidade suficiente para melhorar a relação sinal-ruído e portanto facilitar a detecção estatística das regiões com atividade neural relevante, chamadas aqui simplesmente de *regiões ativadas* (Fair et al., 2007; Gi-

acomantone, 2005).

Devido ao baixo contraste das imagens adquiridas, para possibilitar a identificação das regiões ativadas é necessário realizar um pós-processamento sobre as imagens sob estímulo e sem estímulo. Os métodos de detecção podem ser estatísticos paramétricos ou não-paramétricos.

Este trabalho apresenta uma nova abordagem para a detecção de regiões cerebrais ativadas: os métodos estatísticos clássicos de detecção de regiões ativadas baseados em testes de hipóteses são apresentados como métodos de análise de imagens multiespectrais sintéticas, sendo apresentada uma alternativa a esses métodos baseada na análise de imagens monoespectrais sintéticas utilizando um método não-paramétrico baseado em mapas auto-organizados de Kohonen.

Para validar esta proposta, foi realizado um estudo de caso onde foram adquiridas imagens funcionais eco-planares reais, sob estímulo e sem estímulo. Essas imagens são provenientes de um experimento padrão onde se deseja detectar a área cerebral associada à atenção espacial visual.

Para avaliar os métodos propostos foram calculadas as taxas de falsos positivos, falsos negativos, verdadeiros positivos e verdadeiros negativos, obtidas a partir das matrizes de confusão calculadas durante a etapa de pós-classificação.

2 Materiais e Métodos

As imagens de fMRI foram fornecidas pelo Departamento de Física e pelo Laboratório de Percepção Visual do Departamento de Psicologia da Universidade Federal de Pernambuco, Recife, Brasil. Essas imagens foram adquiridas a partir de um tomógrafo clínico de 1,5 T durante o ano de 2004. Foram adquiridas 60 imagens: 24 sob estímulo, 24 sem estímulo e 12 imagens de referência para corrigir os efeitos de movimento (Bannister et al., 2007).

2.1 Métodos de Detecção Estatísticos Multiespectrais

Uma seqüência temporal de imagens eco-planares pode ser modelada como uma única imagem multiespectral de n bandas, $f : S \rightarrow [0, 1]^n$, com vetor de ativação

$$\mathbf{v} = (v_1, v_2, \dots, v_n)^T,$$

onde, se $v_k = 1$, a banda $f_k : S \rightarrow [0, 1]$ corresponde a uma imagem sob estímulo; caso $v_k = 0$, a banda $f_k : S \rightarrow [0, 1]$ está associada a uma imagem sem estímulo; S é a grade da imagem f , onde $1 \leq k \leq n$.

Seja n_0 o número de bandas associadas às imagens sem estímulo e n_1 o número de bandas relacionadas às imagens sob estímulo, se $n =$

$n_0 + n_1$, considerando as seguintes populações por *voxel*:

$$F_0(\mathbf{u}) = \{f_k(\mathbf{u}) | v_k = 0\}, \quad (1)$$

$$F_1(\mathbf{u}) = \{f_k(\mathbf{u}) | v_k = 1\}, \quad (2)$$

têm-se as seguintes estatísticas de interesse:

$$\bar{F}_0(\mathbf{u}) = \frac{1}{n_0} \sum_{v_k=0} f_k(\mathbf{u}), \quad (3)$$

$$S_0^2(\mathbf{u}) = \frac{1}{n_0 - 1} \sum_{v_k=0} (f_k(\mathbf{u}) - \bar{F}_0(\mathbf{u}))^2, \quad (4)$$

$$\bar{F}_1(\mathbf{u}) = \frac{1}{n_1} \sum_{v_k=1} f_k(\mathbf{u}), \quad (5)$$

$$S_1^2(\mathbf{u}) = \frac{1}{n_1 - 1} \sum_{v_k=1} (f_k(\mathbf{u}) - \bar{F}_1(\mathbf{u}))^2, \quad (6)$$

onde $\bar{F}_0(\mathbf{u})$, $S_0^2(\mathbf{u})$, $\bar{F}_1(\mathbf{u})$ e $S_1^2(\mathbf{u})$ são os respectivos pares média e desvio padrão que estimam os pares esperança e variância $\mu_0(\mathbf{u})$, $\sigma_0^2(\mathbf{u})$, $\mu_1(\mathbf{u})$ e $\sigma_1^2(\mathbf{u})$ para as populações adquiridas sem estímulo e sob estímulo, respectivamente, para cada *pixel* em f com posição $\mathbf{u} \in S$.

A maioria dos métodos estatísticos de detecção são testes de hipótese nula (Lukic et al., 2002), onde se deseja medir o desvio por *voxel* entre as populações sob estímulo e sem estímulo (Thirion et al., 2007). Se esse desvio estiver fora de um determinado intervalo de confiança de probabilidade P_c , o *pixel* correspondente à posição \mathbf{u} no mapa binário de ativação $f_b : S \rightarrow \{0, 1\}$ assume $f_b(\mathbf{u}) = 1$ e é considerado *ativado*; caso contrário, $f_b(\mathbf{u}) = 0$ e o *pixel* correspondente é considerado *não-ativado* (Giacomantone, 2005).

Os métodos de detecção baseados em testes de hipótese nula variam de acordo com a natureza do teste, como segue:

1. *Teste t de Student* (TTS): As variâncias $\sigma_0^2(\mathbf{u})$ e $\sigma_1^2(\mathbf{u})$ são diferentes e desconhecidas.

$$T(\mathbf{u}) = \frac{\bar{F}_0(\mathbf{u}) - \bar{F}_1(\mathbf{u})}{\sqrt{\frac{S_0^2(\mathbf{u})}{n_0} + \frac{S_1^2(\mathbf{u})}{n_1}}}, \quad (7)$$

com

$$\lambda = \frac{\left(\frac{S_0^2(\mathbf{u})}{n_0} + \frac{S_1^2(\mathbf{u})}{n_1}\right)^2}{\frac{(S_0^2(\mathbf{u})/n_0)^2}{n_0+1} + \frac{(S_1^2(\mathbf{u})/n_1)^2}{n_1+1}} - 2 \quad (8)$$

graus de liberdade, onde $\mathbf{u} \in S$;

2. *Teste t Combinado* (TTC): As variâncias $\sigma_0^2(\mathbf{u})$ e $\sigma_1^2(\mathbf{u})$ são iguais e desconhecidas.

$$T(\mathbf{u}) = \frac{\bar{F}_0(\mathbf{u}) - \bar{F}_1(\mathbf{u})}{S_p(\mathbf{u}) \sqrt{\frac{1}{n_0} + \frac{1}{n_1}}}, \quad (9)$$

onde

$$S_p^2(\mathbf{u}) = \frac{(n_0 - 1)S_0^2(\mathbf{u}) + (n_1 - 1)S_1^2(\mathbf{u})}{n_0 + n_1 - 2} \quad (10)$$

é o *estimador combinado* de $\sigma^2(\mathbf{u}) = \sigma_0^2(\mathbf{u}) = \sigma_1^2(\mathbf{u})$ com $\lambda = n_0 + n_1 - 2$ graus de liberdade, onde $\mathbf{u} \in S$;

3. *Teste t Emparelhado* (TTP): Considera as estatísticas das diferentes populações

$$D(\mathbf{u}) = \{f_i(\mathbf{u}) - f_j(\mathbf{u}) | v_i = 0, v_j = 1\}, \quad (11)$$

onde $n_0 = n_1 = n/2$; se $\bar{D}(\mathbf{u})$ e $S_D^2(\mathbf{u})$ são a média e o desvio padrão da população $D(\mathbf{u})$, então o testes estatístico é dado por:

$$T(\mathbf{u}) = \frac{\bar{D}(\mathbf{u})}{S_D(\mathbf{u})/\sqrt{n/2}}. \quad (12)$$

Utilizando as estatísticas T obtidas a partir dos cálculos anteriores e distribuídas segundo uma distribuição t com λ graus de liberdade, pode-se calcular as probabilidades $P_{\mathbf{u}} = P(t \leq T(\mathbf{u}))$, $\forall \mathbf{u} \in S$.

O mapa de ativação binário é composto como segue:

$$f_b(\mathbf{u}) = \begin{cases} 1, & P_{\mathbf{u}} < \frac{1-P_c}{2} \vee P_{\mathbf{u}} > \frac{1+P_c}{2} \\ 0, & \frac{1-P_c}{2} \leq P_{\mathbf{u}} \leq \frac{1+P_c}{2} \end{cases}, \quad (13)$$

onde $\mathbf{u} \in S$. A presença de ruído é caracterizada pela existência de *pixels* isolados marcados como ativados em regiões onde não há amostra cranial. Nestes casos, pode-se aplicar o filtro da moda sobre o mapa f_b para eliminar as falsas detecções, gerando o mapa de ativação filtrado $f'_b : S \rightarrow \{0, 1\}$.

Para avaliar qualitativamente as áreas detectadas é comum compor uma imagem temática a partir da superposição do mapa binário de ativação sobre a imagem anatômica correspondente, rotulando as áreas ativadas com uma cor pré-definida, que recebe o nome de *marcador* (Malinen et al., 2007; Giacomantone, 2005).

A imagem temática de ativação $f_a : S \rightarrow [0, 1]^3$, com mapa de ativação binário filtrado $f'_b : S \rightarrow \{0, 1\}$ e marcador $\mathbf{r} = (r_1, r_2, r_3)^T$, pode ser obtida pela expressão:

$$f_a(\mathbf{u}) = f'_b(\mathbf{u})\bar{F}_1(\mathbf{u})\mathbf{r} + (1 - f'_b(\mathbf{u}))\bar{F}_1(\mathbf{u})(1, 1, 1)^T, \quad (14)$$

onde $\mathbf{u} \in S$.

2.2 Métodos de Detecção Não-Paramétricos Multiespectrais

Os métodos não-paramétricos são baseados em geral na classificação *voxel a voxel* das séries temporais normalizadas utilizando métodos não-supervisionados, tais como os mapas de k-médias, os mapas auto-organizados e os mapas *fuzzy c-médias* (Chen et al., 2006; Dimitriadou et al., 2004; Windischberger et al., 2003; Somorjai et al., 2002).

Contudo, pode-se considerar a tarefa de detectar regiões como na verdade a classificação da imagem multiespectral normalizada de n bandas f' considerando o conjunto de classes $\Omega = \{C_1, C_2, \dots, C_m\}$, onde as primeiras $m - 1$ classes representam os diversos níveis de ativação de interesse detectados e a m -ésima classe representa o fundo da imagem.

Conseqüentemente, a imagem multiespectral normalizada $f' : S \rightarrow [-1, 1]^n$ é definida a partir de f como segue (Dimitriadou et al., 2004):

$$f'_k(\mathbf{u}) = \begin{cases} f_k(\mathbf{u}) - \bar{F}_0, & v_k = 0 \\ f_k(\mathbf{u}) - \bar{F}_1, & v_k = 1 \end{cases}, \quad (15)$$

onde $1 \leq k \leq n$ e $\mathbf{u} \in S$.

A classificação automática de $f' : S \rightarrow [-1, 1]^n$ resulta no mapa de classificação $g : S \rightarrow \{1, 2, \dots, m\}$. O mapa binário de ativação é gerado a partir da seleção da k -ésima classe associada a uma ativação, como segue:

$$f_b(\mathbf{u}) = \begin{cases} 1, & g(\mathbf{u}) = k \\ 0, & g(\mathbf{u}) \neq k \end{cases}, \quad (16)$$

onde $\mathbf{u} \in S$.

Para reduzir a influência das falsas ativações originadas pelo ruído, o mapa binário de ativação f_b é filtrado pelo filtro da moda, resultando f'_b . A imagem temática de ativação f_a é gerada pela superposição de f'_b sobre o mapa anatômico sob estímulo \bar{F}_1 usando o marcador \mathbf{r} , como descrito na equação 14.

2.3 Método de Detecção Não-Paramétrico Monoespectral Proposto

A maior desvantagem do emprego de métodos não-paramétricos é seu alto custo computacional associado, apesar de seus bons resultados na detecção e classificação de diferentes níveis de ativação. Esses métodos lidam com imagens multiespectrais sintéticas com no mínimo 60 bandas durante a fase de treinamento e são responsáveis pela detecção de diferentes níveis de ativação.

Como uma boa solução pode-se gerar uma imagem monoespectral com as diferenças de níveis. Uma imagem candidata pode ser $f_d : S \rightarrow [0, 1]$, definida como as diferenças entre os níveis médios dos sinais sob estímulo e sem estímulo por *voxel*:

$$f_d(\mathbf{u}) = \bar{F}_1(\mathbf{u}) - \bar{F}_0(\mathbf{u}), \quad (17)$$

onde $\mathbf{u} \in S$. Contudo, as regiões ativadas com baixo nível médio de sinal podem não ser detectadas durante a etapa de classificação. Portanto, pode-se modificar o histograma da imagem diferença, gerando a imagem diferença modificada $f'_d : S \rightarrow [0, 1]$ definida por:

$$f'_d(\mathbf{u}) = \left(\frac{\bar{F}_1(\mathbf{u}) - \bar{F}_0(\mathbf{u}) - \lambda_1}{\lambda_2 - \lambda_1} \right)^{1/2}, \quad (18)$$

onde $\mathbf{u} \in S$,

$$\lambda_1 = \bigwedge_{\mathbf{v} \in S} (\bar{F}_1(\mathbf{v}) - \bar{F}_0(\mathbf{v})), \quad (19)$$

e

$$\lambda_2 = \bigvee_{\mathbf{v} \in S} (\bar{F}_1(\mathbf{v}) - \bar{F}_0(\mathbf{v})). \quad (20)$$

A classificação automática de $f'_d : S \rightarrow [0, 1]$ resulta no mapa de classificação $g : S \rightarrow \{1, 2, \dots, m\}$. O mapa de ativação binário $f_b : S \rightarrow \{0, 1\}$ é gerado a partir da seleção da k -ésima classe de interesse associada à ativação, como descrito na equação 16. Os passos seguintes são idênticos aos passos seguidos pelos métodos não-paramétricos citados anteriormente. Na etapa de classificação pode-se usar diversos métodos não-paramétricos (Jarmasz and Somorjai, 2002; Ngan et al., 2002).

A avaliação do resultado é feita a partir de g , utilizando um conjunto de regiões de interesse gerado a partir da seleção da região ativada correspondente, utilizando como referência um atlas funcional que mostra a região do cérebro responsável pela atenção espacial visual (Maldjian et al., 1999). Para avaliar quantitativamente os resultados utiliza-se o índice κ , a acurácia global e a matriz de confusão. Da matriz de confusão calculada foram obtidas as taxas de falsos positivos, falsos negativos, verdadeiros positivos e verdadeiros negativos para cada um dos métodos de detecção apresentados.

2.4 Avaliação de Desempenho

A *matriz de confusão* para o universo de classes de interesse Ω é uma matriz $m \times m$, $\mathbf{T} = [t_{i,j}]_{m \times m}$, onde cada elemento $t_{i,j}$ representa o número de objetos pertencentes à classe C_j classificados como C_i , onde $\Omega = \{C_1, C_2, \dots, C_m\}$ (Duda et al., 2001; Landgrebe, 2002).

A *acurácia global* ϕ é a razão entre o número de objetos corretamente classificados e o total de objetos, definida como segue (Duda et al., 2001; Landgrebe, 2002):

$$\phi = \rho_v = \frac{\sum_{i=1}^m t_{i,i}}{\sum_{i=1}^m \sum_{j=1}^m t_{i,j}}. \quad (21)$$

O *índice κ* é um índice de correlação estatística definido como segue (Duda et al., 2001):

$$\kappa = \frac{\rho_v - \rho_z}{1 - \rho_z}, \quad (22)$$

onde

$$\rho_z = \frac{\sum_{i=1}^m (\sum_{j=1}^m t_{i,j}) (\sum_{j=1}^m t_{j,i})}{(\sum_{i=1}^m \sum_{j=1}^m t_{i,j})^2}. \quad (23)$$




Figura 1: Imagem temática de ativação resultante do Teste t de Student




Figura 2: Imagem temática de ativação resultante do Teste t Emparelhado

3 Resultados

As figuras 1, 2 e 3 mostram as imagens temáticas de ativação $f_a : S \rightarrow [0, 1]^3$ resultantes da detecção utilizando o Teste de t de Student, o Teste t Emparelhado e o Teste t Combinado, com probabilidade de confiança $P_c = 95\%$ e marcador \mathbf{r} vermelho, usando a notação RGB, $\mathbf{r} = (1, 0, 0)^T$.

A figura 4 mostra a imagem diferença modificada $f'_d : S \rightarrow [0, 1]$. Pode-se perceber tanto as regiões ativadas quanto as falsas ativações devidas à presença do ruído em todos os experimentos

A figura 5 mostra a imagem temática de




Figura 3: Imagem temática de ativação resultante do Teste t Combinado

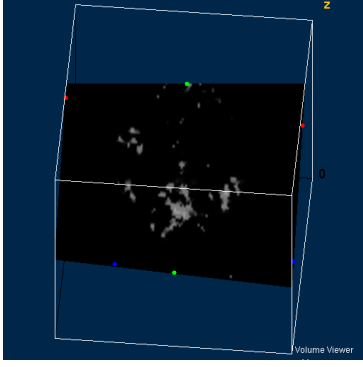


Figura 4: Imagem diferença modificada

	TTS	TTC	TTP	KO
κ	0.59	0.59	0.66	0.71
ϕ (%)	78.53	78.53	82.61	85.33

Tabela 1: Avaliação de desempenho por meio da acurácia global ϕ e do índice κ

ativação $f_a : S \rightarrow [0, 1]^3$ obtida da imagem anatômica de ativação $\bar{F}_1 : S \rightarrow [0, 1]$ e o mapa binário de ativação filtrado $f'_b : S \rightarrow [0, 1]$ resultante da classificação da imagem diferença modificada utilizando um mapa auto-organizado de Kohonen (KO), com uma entrada, 3 saídas, 50 iterações durante a etapa de treinamento e taxa de aprendizado inicial $\eta = 0, 1$.

A avaliação do desempenho da classificação foi realizada por meio de regiões de interesse adquiridas de um atlas fMRI com experimentos em sistemas de 4 T (Maldjian et al., 1999). A tabela 1 mostra a avaliação dos métodos de detecção apresentados usando o índice κ e a taxa de acurácia global ϕ (%), enquanto a tabela 2 fornece as taxas de falsos positivos (FP), falsos negativos (FN), verdadeiros positivos (TP) e verdadeiros negativos (TN).

4 Discussão e Conclusões

Analisando os índices de pós-classificação κ a partir da tabela 1, pode-se perceber que a classificação pelo mapa auto-organizado de Kohonen resultou numa maior correlação estatística ($\kappa = 0.71$) entre os resultados e o conjunto de teste do que a aplicação dos métodos estatísticos clássicos ($\kappa = 0.59$ para o Teste t de Student e para o Teste

	TTS	TTC	TTP	KO
TN (%)	100,00	100,00	100,00	100,00
FN (%)	0,00	0,00	0,00	0,00
FP (%)	34,80	34,80	28,19	23,79
TP (%)	65,20	65,20	71,81	76,21

Tabela 2: Avaliação de desempenho utilizando taxas de detecção




Figura 5: Imagem temática de ativação resultante da classificação pelo mapa auto-organizado de Kohonen

t Combinado, e $\kappa = 0.66$ para o Teste t Emparelhado). Esses resultados são confirmados pela acurácia global: $\phi = 85.33\%$ para o método KO contra $\phi = 78, 53\%$ para os métodos TTS e TTC, e $\phi = 82, 61\%$ para o método TTP.

A tabela 2 mostra as taxas TN, FN, FP e TP para os métodos de detecção apresentados. Essas taxas são calculadas a partir das matrizes de confusão obtidas no processo de pós-classificação utilizando um conjunto de teste composto por determinadas regiões de interesse de referência e considerando apenas duas classes: sob estímulo e sem estímulo. Conseqüentemente, TN e TP pertencem à diagonal principal dessas matrizes de confusão.

Analisando a tabela 2, pode-se perceber que todos os métodos de detecção resultaram na ausência de *voxels* falsamente ativadas. Entretanto, as taxas de falsos positivos foram bastante significativas, devido a uma possível imprecisão na seleção das regiões de interesse pelo especialista, uma vez que essa seleção é realizada através da análise visual de um atlas de ativação de fMRI (Maldjian et al., 1999). A imprecisão pode aumentar ainda mais devido ao fato de as imagens EPI serem de baixa resolução anatômica (Haacke et al., 1999). A resolução anatômica também decresce com o aumento do campo magnético estático, como pode ser demonstrado por experimentos de fMRI em tomógrafos de ressonância magnética de 4 T (Maldjian et al., 1999).

A taxa de falsos positivos foi de 34.80% para os métodos TTS e TTC, 28,19% para o método TTP e 23,79% para o método não-paramétrico KO. Essa taxa é significativa, dado o fato de que os métodos foram aplicados a imagens reais e, portanto, há outros tipos de atividade cerebral, que não aquela relacionada à atenção espacial visual, ocorrendo simultaneamente. Esses resultados colocam o mapa auto-organizado de Kohonen numa posição superior em relação aos testes estatísticos t de hipótese nula. O método KO é também computacionalmente superior quando comparado com a maioria dos métodos estatísticos

de detecção clássicos, devido à sua natureza monoespectral, em contraste com os outros métodos apresentados, uma vez que a análise de seqüências temporais de imagens EPI é na verdade uma análise *pixel a pixel* de uma imagem multiespectral sintética composta por imagens EPI sob estímulo e sem estímulo.

Portanto, o método de detecção baseado no mapa auto-organizado de Kohonen proposto neste trabalho tem a vantagem adicional de reduzir um problema multiespectral a uma abordagem monoespectral, eliminando o custo computacional associado à estimação das funções de distribuição de probabilidade acumulada utilizadas nos testes de hipótese nula.

Agradecimentos

Ao CNPq, pelo financiamento de parte deste trabalho.

Referências

- Bandettini, P. (2007). Functional mri today, *International Journal of Psychophysiology* .
- Bannister, P. R., Brady, J. M. and Jenkinson, M. (2007). Integrating temporal information with a non-rigid method of motion correction for functional magnetic resonance images, *Image and Vision Computing* (25): 311–320.
- Bartsch, A. J., Homola, G., Thesen, S., Sahmer, P., Keim, R., Beckmann, C. F., Biller, A., Knaus, C. and Bendszus, M. (2007). Scanning for the scanner: fmri of audition by read-out omissions from echo-planar imaging, *NeuroImage* (35): 234–243.
- Chen, W., Giger, M. L. and Bick, U. (2006). A fuzzy c-means (fcm)-based approach for computerized segmentation of breast lesions in dynamic contrast-enhanced MR images, *Academic Radiology* **13**(1): 63–72.
- Dimitriadou, E., Barth, M., Windischberger, C., Hornik, K. and Moser, E. (2004). A quantitative comparison of functional MRI cluster analysis, *Artificial Intelligence in Medicine* (31): 57–71.
- Duda, R., Hart, P. and Stork, D. G. (2001). *Pattern Classification*, John Wiley and Sons.
- Fair, D. A., Schlaggar, B. L., Cohen, A. L., Miezin, F. M., Dosenbach, N. U. F., Wenger, K. K., Fox, M. D., Snyder, A. Z., Raichle, M. E. and Petersen, S. E. (2007). A method for using blocked and event-related fmri data to study ‘resting state’ functional connectivity, *NeuroImage* (35): 396–405.
- Giacomantone, J. O. (2005). *Ressonância magnética funcional com filtragem pela difusão anisotrópica robusta*, Master’s thesis, Programa de Pós-Graduação em Engenharia Elétrica da Universidade de São Paulo, São Paulo, Brasil.
- Haacke, E. M., Brown, R. W., Thompson, M. R. and Venkatesan, R. (1999). *Magnetic Resonance Imaging: Physical Principles and Sequence Design*, Wiley-Liss.
- Jarmasz, M. and Somorjai, R. L. (2002). Exploring regions of interest with cluster analysis (eroica) using a spectral peak statistic for selecting and testing the significance of fmri activation time series, *Artificial Intelligence in Medicine* (25): 45–67.
- Landgrebe, D. (2002). Hyperspectral image analysis, *IEEE Signal Processing Magazine* .
- Lukic, A. S., Wernick, M. N. and Strother, S. C. (2002). An evaluation of methods for detecting brain activations from functional neuroimages, *Artificial Intelligence in Medicine* (25): 69–88.
- Maldjian, J. A., Gottschalk, A., Patel, R. S., Detre, J. A. and Alsop, D. C. (1999). The sensory somatotopic map of the human hand demonstrated at 4 tesla, *NeuroImage* (10): 55–62.
- Malinen, S., Hlushchuk, Y. and Hari, R. (2007). Towards natural stimulation in fmri: Issues of data analysis, *NeuroImage* (35): 131–139.
- Ngan, S. C., Yacoub, E. S., Auffermann, W. F. and Hu, X. (2002). Node merging on kohonen’s self-organizing of fmri data, *Artificial Intelligence in Medicine* (25): 19–33.
- Somorjai, R. L., Vivanco, R. and Pizzi, N. (2002). A novel, direct spatio-temporal approach for analyzing fmri experiments, *Artificial Intelligence in Medicine* (25): 5–17.
- Thirion, B., Pinel, P., Mériaux, S., Roche, A., Dehaene, S. and Poline, J. B. (2007). Analysis of a large fmri cohort: Statistical and methodological issues for group analyses, *NeuroImage* (35): 105–120.
- Windischberger, C., Barth, M., Lamm, C., Schroeder, L., Bauer, H., Gur, R. C. and Moser, E. (2003). Fuzzy cluster analysis of high-field functional MRI data, *Artificial Intelligence in Medicine* (29): 203–223.