

Agrupamento de Sinais de Eletroencefalografia Utilizando Mapas Auto-Organizáveis.

Vinicius de Melo Maciel*

George F. von Borries†

Ricardo F. von Borries‡

1 de maio de 2010

1 Resumo

Neste estudo foi utilizado a técnica de agrupamento de mapas auto-organizáveis a fim de identificar grupos de sinais com características similares, a partir de um certo estímulo visual. Verificou-se que é possível agrupar corretamente os dados coletados durante certo estímulo visual e que o mapa resultante da análise torna evidente muitas características que são anteriormente desconhecidas. Foi visto que não é possível, apenas com o agrupamento, classificar novas observações em um dos grupos e prever o estímulo recebido, sem seu prévio conhecimento.

Palavras-chave: *Eletroencefalografia, Mapas Auto-Organizáveis, SOM.*

2 Introdução

Estudos recentes em processamento digital de sinais permitem a detecção de diferentes atividades mentais através dos sinais elétricos gerados pelo cérebro. A captação destes sinais é feita pela Eletroencefalografia (EEG), técnica não invasiva que requer apenas o posicionamento de eletrodos na superfície da cabeça para obter o registro do potencial elétrico produzido pelo cérebro em um dado momento.

Nesta pesquisa, trabalhamos com dados coletados pelo Biopotentials Image Laboratory da Universidade do Texas em El Paso, referentes aos dados de Eletroencefalografia (EEG) obtidos de um indivíduo submetido a diferentes estímulos visuais. Existe uma vasta gama de aplicações da eletroencefalografia atualmente. Entre as pesquisas desenvolvidas dentro da área, tem aquelas direcionadas para o desenvolvimento de próteses mecânicas que respondem aos sinais do cérebro através de um aparelho de leitura dos sinais cerebrais.

A procura de um padrão nos sinais coletados é feita através da análise de agrupamentos, que consiste na criação de grupos para as observações baseando-se na similaridade existente entre elas em relação as variáveis em estudo.

*Departamento de Estatística, IE, Universidade de Brasília, Brasília, DF, 70910-900, Brazil, E-mail: vini_313@hotmail.com

†Departamento de Estatística, IE, Universidade de Brasília, Brasília, DF, 70910-900, Brazil, E-mail: gborries@unb.br

‡Department of Electrical and Computer Engineering, University of Texas at El Paso, El Paso, Texas, 79968-0523, USA, E-mail: rvonborries@utep.edu

3 Descrição do Experimento

Os sinais elétricos emitidos pelo cérebro foram coletados durante um estímulo visual apresentado ao indivíduo por um certo período de tempo (aproximadamente 4 segundos), conforme figura 3. A gravação dos sinais emitidos pelo cérebro foi realizada através de 128 eletrodos posicionados no couro cabeludo. Após a gravação os sinais de cada eletrodo passaram por um tratamento e foram divididos em 32 bandas cada, de tal forma que cada banda contém uma diferente característica do sinal original.



Figura 1: Visualização do Experimento

Dez diferentes estímulos visuais foram apresentados ao indivíduo, sendo que foi utilizado apenas três dessas nesta pesquisa (figuras A, B e C), conforme mostrado a seguir.



Figura 2: Figuras A, B e C

4 Mapas Auto-Organizáveis

Os mapas auto organizáveis (SOM - Self-Organizing Maps) são redes competitivas que possuem a habilidade de formar mapeamentos que preservam as mais importantes relações topológicas e/ou métricas dos dados primários.

O SOM é essencialmente um redutor de dimensões, mapeando as similaridades dos dados e organizando objetos parecidos conjuntamente. Esta técnica é atrativa na análise de agrupamentos e sua visualização, pois projeta e visualiza dados de altas dimensões em um cenário de duas dimensões, indicando regiões de similaridade.

O SOM define um mapeamento a partir dos dados de entrada, no espaço \mathcal{R}^m , em uma matriz de unidades de informação (nódulos) em duas ou três dimensões, onde o número de nódulos utilizado pelo algoritmo (número de grupos) deve ser definido pelo pesquisador no começo do algoritmo e disposto em forma de matriz. A cada nódulo i é associado um modelo de vetor paramétrico, também chamado de vetor referência. O algoritmo responsável pela formação do SOM primeiramente atribui pesos aos vetores referência da rede de nódulos do mapa de características. Esta etapa é chamada de inicialização.

Após esta etapa, o algoritmo compara cada observação \mathbf{x} com todos os vetores referência, à procura daquele mais "próximo" da observação, modificando o vetor referência do grupo que a recebe e da sua vizinhança, exemplificado na figura 5.2 seguinte. Este procedimento se resume nos três processos seguintes: competição, cooperação e adaptação.




Figura 3: Desenho esquemático do mapa de características (retirado de <http://www.sis.pitt.edu/ssyn/som/som.html>)

No processo competitivo, seja $\mathbf{x} = (x_1, x_2, \dots, x_m)'$ um objeto selecionado aleatoriamente do espaço de entrada (dados de entrada), onde m é a sua dimensão e \mathbf{w}_j o vetor de pesos do nó j , denotado por

$$\mathbf{w}_j = (\omega_{j1}, \omega_{j2}, \dots, \omega_{jm})', j = 1, 2, \dots, l,$$

onde l é o número de nós no mapa de características. Compara-se a observação \mathbf{x} com todos os nós do mapa de características e a copia em uma sub lista associada ao nó que se apresentou mais similar (vencedor i).

O processo cooperativo considera a vizinhança do nó vencedor i , que será chamada de N_i , consistindo de todos os nós em um certo raio. Pode-se dizer que o nó vencedor, recebendo a observação \mathbf{x} , influencia o vetor de pesos dos nós de N_i , com mais força na vizinhança imediata de i e com cada vez menos força a medida que nos afastamos. Nesta etapa, será construída uma *função de vizinhança espacial* que determinará como o nó i influenciara a vizinhança, onde:

- $h_{j,i}$ atinge seu maior valor no nó i .
- A amplitude de $h_{j,i}$ decai monotonicamente com o aumento da distância lateral e cai para zero quando a distância tende ao infinito.

No processo adaptativo os nós vizinhos no arranjo do mapa de características irão contactar um ao outro para "aprender" algo sobre o objeto \mathbf{x} , utilizando a função de vizinhança da etapa anterior. Este contato irá provocar um relaxamento ou suavização sobre os vetores de pesos na proximidade do nó vencedor i , levando à um ordenamento global, em um aprendizado contínuo com iterações suficientes.

No processo de adaptação, o vetor referência do nó j , vizinho do vencedor i , também muda com a associação do objeto \mathbf{x} . Dado os pesos $\mathbf{w}_j(t)$, no tempo ou iteração t , tem-se o novo vetor de pesos $\mathbf{w}_j(t+1)$, no tempo $t+1$, definido por

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + \alpha(t)h_{j,i}(t)[\mathbf{x} - \mathbf{w}_j(t)], \quad (1)$$

onde $\alpha(t)$ é um parâmetro de velocidade de aprendizado, que diminui com o tempo t e varia entre 0 e 1, e é definido por

$$\alpha(t) = \alpha(0) \exp\left\{\frac{-t}{\tau_2}\right\}, t = 1, 2, \dots, e$$

$\alpha(0)$ é o valor do parâmetro de aprendizado no começo do algoritmo.

Estes processos são repetidos sucessivamente para cada observação até que nenhuma mudança seja percebida no mapa de características.

5 Resultados

Como primeiro passo, foi estudado se o número de bandas influencia de forma significativa no resultado. Utilizando o Índice Ajustado de Rand (ARI), medida de qualidade externa do agrupamento, que utiliza a comparação do resultado do agrupamento com o grupo real da observação (varia entre -1 e 1 e deve ser maximizada), realizou-se o SOM para diferentes números de grupos e foi observado que o número de bandas não influencia a qualidade do resultado. Deste modo, utilizou-se apenas 4 bandas na análise.

Com índice ajustado de Rand de 0,93, o SOM obteve bom agrupamento com 32 grupos (matriz 4x8) para as três figuras em estudo. Notou-se pela figura a seguir que a figura C tem proximidade com a figura A, e esta com a figura B.




Figura 4: Mapa dos resultados para o agrupamento com trinta e dois grupos em um mapa de características 4x8. (Figura A:Vermelho (1), B:Azul (3) e C: Rosa (5))

Foi percebido que poucos clusters têm alguma variável em destaque na formação dos clusters, que as observações estão distribuídas de forma parecida entre os clusters, que os clusters são significativamente homogêneos dentro de si e heterogêneos entre si.

Observou-se que a figura do novo indivíduo foi agrupada em um grupo separado do estímulo do sujeito base, pois apesar da proximidade para com as outras, o algoritmo identifica um padrão específico para ela, separando suas observações das demais.

Por esta razão, não é possível identificar o tipo de estímulo simplesmente agrupando a figura junto com as anteriores. É necessário um algoritmo de predição e classificação. Deste modo, a figura do novo indivíduo seria obrigatoriamente classificada em um dos grupos que tenha maior proximidade, identificando sua figura, sem o seu prévio conhecimento.

Dentre muitos algoritmos de predição e classificação, o algoritmo "predict" (do software R) realizou a predição das observações da figura B, de um novo sujeito, nos grupos formados pelo SOM. A predição foi correta em 100% das novas observações, as agrupando em clusters separados. Esta técnica se mostrou bastante promissora e deve ser estudada em estudos posteriores, junto com outras técnicas de predição e classificação, combinadas com técnicas de agrupamento.

6 Conclusão

- A utilização de poucas bandas na análise não trás prejuízos para a análise.
- O SOM obteve bom agrupamento com 32 grupos para as três figuras em estudo.
- Foi percebido que poucos grupos têm alguma variável em destaque na sua formação, que as observações estão distribuídas de forma parecida entre os grupos, e que estes são significativamente homogêneos dentro de si e heterogêneos entre si.
- A técnica de Mapas Auto-Organizáveis apresentou bons resultados no agrupamento dos três tipos de estímulos visuais (A, B, e C).
- Não é possível identificar o tipo de estímulo de um novo sujeito simplesmente agrupando a figura junto com as anteriores.
- É necessário um algoritmo de predição e classificação a ser usado em conjunto com o resultado do agrupamento para a identificação da nova observação.
- Dentre muitos algoritmos de predição e classificação, o algoritmo "predict" (do software R) mostrou-se bastante promissor.

Referências

- [1] JULIAN A. *Modern Multivariate Statistical Techniques*, chapter 12, pages 431–434. Springer, 2008.
- [2] RENCHER A. *Methods of Multivariate Analysis*, chapter 14, pages 451–503. Wiley, 2002.
- [3] KRUSIENSKI D., SELLERS E., CABESTAING F., and BAYOUDH S. A comparison of classification techniques for p300 speller. *Journal of Neural Engineering*, 3:299–305, 2006.
- [4] CÉSAR F. and CRISTINA M. Mapas auto-organizados de kohonen - som. Master's thesis, Pontifce Universidade Católica do Rio Grande do Sul, 2001.
- [5] BROCK G., PIHUR V., DATTA S., and DATTA S. Clvalid: An r package for cluster validation. *Journal of Statistical Software*, 25:22, 2008.
- [6] FUNG G. A comprehensive overview of basic clustering algorithms. June 22, 2001.
- [7] GAN G., HA C., and Wu J. *Data Clustering Theory, Algorithms and Applications*, chapter 5, pages 56–59. SIAM, 2007.
- [8] Bronzino J. *The Biomedical Engineering Handbook*, volume 1, chapter 15, page 1656. CRC Press, 2000.
- [9] Lee J.C. and Tan D.S. Using a low-cost electroencephalograph for task classification in hci research. *Proceedings of the ACM symposium on User Interface Software and technology (UIST)*, 19:81 – 90, 2006.
- [10] YEUNG K. and RUZZO W. An empirical study on principal component analysis for clustering gene expression data (suplemento). *Bioinformatics*, 17(9):763–774, 2001.
- [11] HUBERT L. and ARABIE P. Comparing partitions. *Journal of Classification*, 2:193–218, 1985.

[12] KOHONEN T. *Self-Organizing Maps*. Springer, 2000.