

IDENTIFICAÇÃO DE REGIÕES ATIVADAS DO CÉREBRO ATRAVÉS DE EEG DE ESTÍMULOS VISUAIS

George Freitas von BORRIES¹
Loyane Christina Soares ROCHA²
Murilo COUTINHO²
Ricardo Freitas von BORRIES³

- RESUMO: Técnicas recentes em processamento digital de sinais permitem a detecção de diferentes tipos de atividade mental através de biopotenciais gerados pelo cérebro. Métodos de eletroencefalografia (EEG), em oposição a métodos invasivos, têm a vantagem de exigir apenas biopotenciais de superfície e serem mais adequados, para uso regular, em equipamentos de interface homem máquina e para aplicações como a classificação de padrões no pensamento para o controle de máquinas por pessoas com problemas motores. Este artigo utiliza as técnicas de análise de componentes principais (ACP) e análise de componentes independentes (ACI) em dados de eletroencefalografia (EEG) para investigar as áreas mais ativadas do cérebro quando este é submetido a uma sequência de estímulos visuais. A principal diferença da abordagem adotada neste estudo e outras abordagens é a seleção dos eletrodos originais através de ACP e ACI em vez do uso de combinações destes eletrodos por componentes selecionadas de cada técnica. Os dados foram coletados no laboratório “Multi-Sensing-Processing & Learning” da Universidade do Texas em El Paso, utilizando um sistema de aquisição com 128 eletrodos. A redução e identificação dos principais eletrodos na coleta de dados de EEG permite a compreensão da atividade cerebral realizada durante diferentes tarefas e a redução do número de dimensões em procedimentos de classificação. Empregando apenas os sinais provenientes dos eletrodos selecionados, foi realizado um estudo comparativo das taxas de classificação dos estímulos visuais ao aplicar as técnicas de Análise Discriminante Linear (ADL), Análise Discriminante Quadrática (ADQ) e Máquinas de Vetores de Suporte (SVM). Foi possível concluir que as taxas de classificação foram superiores às obtidas ao utilizar todos os sinais. No entanto, não foi possível identificar diferenças

¹Universidade de Brasília – UNB, Instituto de Ciências Exatas – IE, Departamento de Estatística, CEP: 70910-900, Brasília, DF, Brasil. E-mail: gborries@unb.br.

²Universidade de Brasília – UNB, Instituto de Ciências Exatas – IE, Programa de pós-graduação em Estatística, CEP: 70910-900, Brasília, DF, Brasil.

³Universidade do Texas em El Paso – UTEP, Colégio de Engenharia, Departamento de Engenharia Elétrica e Computacional, EL Paso, EUA.

significativas entre a eficiência das técnicas de ACP e ACI quanto à redução proporcionada por cada uma delas, apesar de cada técnica indicar áreas ativadas distintas.

- PALAVRAS-CHAVE: Análise de componentes principais (ACP); análise de componentes independentes (ACI); eletroencefalografia (EEG); estímulo visual; análise discriminante; máquinas de vetores de suporte (SVM).

1 Introdução

Eletroencefalografia (EEG) é uma técnica de captação de sinais elétricos cerebrais de maneira não-invasiva que realiza o registro dos sinais elétricos diretamente da superfície craniana, como relatado em Sörnmo e Laguna (2005), sendo, portanto, adequada para usos regulares em equipamentos de interface homem-máquina. Neste contexto, técnicas estatísticas de reconhecimento de padrões são fundamentais para a detecção e a interpretação da informação contida nos sinais elétricos. A análise de EEG através do uso de interfaces de alta densidade (i.e., com grande número de eletrodos) produz uma grande quantidade de informação em um número elevado de dimensões. Assim, a identificação de regiões mais informativas do cérebro é importante para facilitar a interpretação e representação das propriedades principais dos sinais de EEG coletados (Vigário *et al.*, 2000). Duas técnicas que auxiliam nestes objetivos são a análise de componentes principais (ACP) e análise de componentes independentes (ACI).

A ACP é uma técnica que procura projeções lineares de um conjunto de dados num espaço de dimensão menor que o observado. A técnica retorna componentes decorrelacionadas e ordenadas de forma decrescente em função da variação total explicada pelos dados originais (Johnson e Wichern, 2007). A ACI, por sua vez, identifica componentes ou fontes mutuamente independentes e em ordem aleatória (Hyvärinen, Karhunen e Oja, 2001). A ACI pode ser utilizada também para redução de dimensão. Em termos computacionais a ACP utiliza momentos de segunda ordem (variância) enquanto a ICA utiliza momentos de ordem superior para identificação das componentes.

Hyvärinen, Karhunen e Oja (2001) apresentam uma visão geral dos conceitos básicos de ACI com o respectivo desenvolvimento matemático. Uma abordagem não muito diferente também consta em Hyvärinen, Hurri e Hoyer (2009). A comparação entre as técnicas ACP e ACI, além de um estudo aprofundado sobre quatro diferentes algoritmos para a obtenção da ACI, pode ser encontrada em Mutihac e Mutihac (2007). Lotte *et al.* (2007) apresenta uma revisão dos algoritmos de classificação para dados de EEG em problemas de interface homem-máquina.

Diversos autores têm utilizado ACP e/ou ACI como técnicas de redução e extração de padrões em dados de registros elétricos como uma etapa precedente à classificação. Subasi e Gursoy (2010) aplicam ACP, ACI e ADL (Análise Discriminante Linear) em dados de EEG para remover características irrelevantes e redundantes e utilizam as combinações lineares obtidas como *input* para a etapa de classificação com a técnica de Máquinas de Vetores de Suporte (SVM) em

estudos de crises epilépticas. Nesse mesmo contexto, Mahajan *et al.* (2011) propõem a decomposição dos sinais de EEG em sub-bandas de frequência a partir da transformada wavelet discreta (TWD), aplicam ACP e ACI como técnicas redutoras e os resultados servem como entradas para o classificador de redes neurais. Yu e Chou (2009) também utilizam ACP e ACI para extração de padrões (*feature extraction*) e usam os resultados como dados de entrada para MSV e Redes Neurais Probabilísticas (RNP) com o objetivo de realizar diagnóstico computacional de doenças do coração baseado em sinais de eletrocardiograma (ECG).

Entretanto, todos os estudos supracitados utilizaram os resultados obtidos a partir das técnicas redutoras como *input* para os classificadores. O objetivo deste estudo é propor a utilização das técnicas redutoras para identificar os eletrodos com maiores contribuições nas componentes (combinações lineares obtidas a partir da ACP e da ACI) mais importantes e, portanto, trabalhar com os dados originais destes eletrodos. Foram considerados, ao utilizar ACP, os eletrodos ativados pela primeira componente, pois em componentes principais a primeira componente é a que agrega a maior informação. Já em ACI considerou-se a componente com maior norma L_2 em relação às linhas da matriz de separação, como proposto em Yu e Chou (2009), pois essa componente é a que apresenta a menor informação mútua. Possuir a maior norma, implica também que os sinais detêm maior energia ou variação (Mutihac e Mutihac, 2007). A componente com menor norma foi considerada como uma forma de validação da escolha de componentes com maior variação a partir da norma euclidiana.

Após a aplicação das técnicas de redução para identificação dos eletrodos correspondentes aos sinais mais representativos, foram processadas, como classificadores de sinais, análises discriminantes linear (ADL) e quadrática (ADQ) e Máquinas de Vetores de Suporte (SVM) com o intuito de comparar as taxas de classificação considerando todos os eletrodos ou apenas os eletrodos selecionados por ACP e ACI bem como verificar a eficiência na redução da informação.

Os dados utilizados foram coletados no laboratório Multi-Sensing-Processing and Learning (MSPL), localizado na Universidade do Texas em El Paso, EUA. Os resultados mostram que a classificação utilizando apenas os sinais correspondentes aos eletrodos identificados pelas técnicas de ACP e ACI sempre superaram a classificação realizada sem a prévia aplicação de técnicas redutoras, i.e., utilizando os sinais de todos os eletrodos.

Assim, seguindo a organização deste artigo, a Seção 2 indica como foi a coleta dos dados utilizados. A Seção 3 aborda as técnicas de redução, relatando as principais características da ACP, da ACI e uma breve comparação entre ambas. A Seção 4 contém a metodologia utilizada para indentificação de regiões ativadas do cérebro. Os resultados e a conclusão encontram-se nas Seções 5 e 5, respectivamente.

2 Coleta dos dados

Os dados deste estudo foram coletados no laboratório *Multi-Sensing-Processing and Learning* (MSPL) da Universidade do Texas em El Paso, Estados

Unidos. Os dados consistem de sinais elétricos do cérebro (eletroencefalograma) coletados na superfície da pele do crânio utilizando equipamento Biosemi ActiveTwo com 128 canais, amplificador DC, 24 bits de resolução e eletrodos ativos (com amplificadores) do tipo pino, taxa de amostragem de 2048 Hz, largura de banda (-3dB) de 400 Hz e touca Biosemi com 128 eletrodos ativos com gel para contato com a pele. O método é, portanto, não-invasivo e não oferece riscos aos voluntários participantes do estudo.

Na Figura 1 estão apresentadas os 10 estímulos visuais (imagens) apresentado 5 vezes, em ordem aleatória, e com duração de 4 segundos em cada repetição. Maiores detalhes da metodologia de pesquisa estão disponíveis em Frondana (2011).

A proposta do estudo do MSPL é permitir o desenvolvimento de uma metodologia capaz de classificar corretamente um sinal desconhecido em alguma classe previamente estabelecida por uma amostra de treinamento. Aqui, ACP e ACI são utilizadas com o objetivo de encontrar um número reduzido de eletrodos que mantenha ou melhore a qualidade da informação fornecida.




Figura 1 - Estímulos visuais do experimento para captura de sinais de EEG.

3 Técnicas de redução de dados

A utilização de muitos eletrodos para a captação dos sinais permite uma maior quantidade de informação global mas, por outro lado, implica na obtenção de sinais redundantes e altamente correlacionados. As técnicas de análise de componentes principais e análise de componentes independentes são capazes de transformar o conjunto de variáveis do estudo em algumas combinações lineares das mesmas variáveis, reduzindo assim a dimensionalidade do estudo e retornando, respectivamente, componentes não correlacionadas e componentes independentes.

3.1 Redução por componentes principais

A análise de componentes principais é uma técnica exploratória utilizada para explicar a estrutura de variância-covariância de um conjunto original de variáveis redimensionando esse espaço de variáveis em um conjunto de menor dimensão. Seja

Σ a matriz de covariâncias associada ao vetor aleatório $\mathbf{X}' = [X_1, X_2, \dots, X_p]$. Sejam $(\lambda_1, \mathbf{e}_1), (\lambda_2, \mathbf{e}_2), \dots, (\lambda_p, \mathbf{e}_p)$ os pares de autovalores e autovetores da matriz Σ tais que $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$. A i -ésima componente principal é dada por

$$Y_i = \mathbf{e}'_i \mathbf{X}, \quad i = 1, 2, \dots, p. \quad (1)$$

A primeira componente principal é a que possui a maior parte da variância original. A segunda componente principal é a que possui a maior parte da variância remanescente, tal que seja não correlacionada com a primeira componente e assim sucessivamente.

Em bancos de dados cujas variáveis são fortemente correlacionadas - como no caso de dados de EEG - a técnica de componentes principais é muito útil na redução da dimensão do problema. Esse tipo de análise, em muitos casos, também é capaz de revelar relações inesperadas ou difíceis de se identificar entre as variáveis. Para mais detalhes o leitor deve consultar Johnson e Wichern (2007).

Neste artigo a técnica de componentes principais é utilizada para identificar as regiões mais ativadas no córtex cerebral ao selecionar os eletrodos com maiores pesos na formação da componente principal de maior variância.

Análise de componentes principais não é a única maneira disponível para reduzir a dimensão do estudo. Neste artigo utilizou-se também uma técnica em constante expansão, sobretudo na área de sinais de biopotenciais, denominada análise de componentes independentes.

3.2 Redução por componentes independentes

A análise de componentes independentes é um método para identificar fontes, mutuamente independentes e não gaussianas, a partir de um determinado modelo de mistura das fontes originais (Hyvärinen et al., 2001). De fato, no máximo uma CI pode ter distribuição gaussiana (Hyvärinen et al., 2001 e Hyvärinen et al., 2009) sem que haja comprometimento das estimativas. ACI tem sido bastante utilizada em problemas de telecomunicações, processamento de sons e imagens, econometria, engenharia biomédica e sinais elétricos do corpo humano (Hyvärinen et al., 2001; Izenman, 2008; Stone, 2004).

Matricialmente a mistura no modelo de análise de componentes independentes pode ser representada por

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (2)$$

onde $\mathbf{x}' = [\mathbf{x}_1, \dots, \mathbf{x}_p]$ é a matriz com p características (ou sinais) misturados, $\mathbf{s}' = [\mathbf{s}_1, \dots, \mathbf{s}_q]$ é a matriz com q características (ou sinais) originais e \mathbf{A} é a matriz composta pelos coeficientes de misturas (a_{ij}). Em determinado instante do tempo a i -ésima mistura é descrita como

$$\begin{aligned} \mathbf{x}_i &= a_{i1}s_{i1} + \dots + a_{ij}s_j, & i &= 1, 2, \dots, p \\ & & j &= 1, 2, \dots, q \end{aligned} \quad (3)$$

Neste modelo, apenas \mathbf{x} é conhecido e tanto \mathbf{s} quanto \mathbf{A} devem ser estimados somente com base nas observações \mathbf{x} e na suposição de independência entre os elementos de \mathbf{s} . Após o conhecimento de \mathbf{A} , podemos estimar também a matriz de separação \mathbf{B} com os respectivos coeficientes de separação. As fontes ou componentes independentes podem ser extraídas pelo modelo

$$\mathbf{s} = \mathbf{B}\mathbf{x} \quad (4)$$

Para facilitar a estimação das componentes independentes (CIs) e o desempenho dos algoritmos (Hyvärinen et al., 2001), a primeira etapa a ser realizada é o pré-processamento dos dados, onde as variáveis observadas são centradas e branqueadas (variáveis descorrelacionadas com variância unitária). Após esse branqueamento, a matriz de misturas \mathbf{A} passa a pertencer apenas ao espaço de matrizes ortogonais, reduzindo consideravelmente a quantidade de parâmetros a serem estimados. Um outro ponto importante que facilita a obtenção das CIs é considerar a matriz de misturas \mathbf{A} como quadrada, i.e., estimar um número de fontes semelhante à quantidade de misturas.

A etapa seguinte é a mensuração da não-gaussianidade dentro do subespaço de sinais branqueados (Yu e Chou, 2009). A curtose é uma medida utilizada para esse fim, mas apesar de ser de fácil obtenção, apresenta sensibilidade a outliers. Alternativamente, pode-se utilizar medidas relacionadas à teoria da informação, como negentropia e informação mútua que atuam de forma complementar uma em relação à outra. Negentropia funciona como a distância de uma variável aleatória à gaussianidade. A negentropia é invariante a transformações lineares inversíveis. Informação mútua (IM) contabiliza a quantidade de informação que uma variável fornece de outra e sua nulidade significa que a distribuição conjunta dos valores dos sinais produz exatamente a mesma quantidade de informação dos sinais considerados separadamente, i.e., os sinais são independentes (Mutihac R. e Mutihac R.C., 2007).

As componentes independentes podem ser obtidas utilizando vários algoritmos, que diferem entre si principalmente pelo método de mensuração da não-gaussianidade. Um estudo comparativo entre quatro algoritmos pode ser encontrado em Mutihac R. e Mutihac R.C. (2007). Aqui empregamos o algoritmo do ponto fixo ou *FastICA* descrito em Hyvärinen e Oja (2000), e que utiliza, para a obtenção das CIs, a maximização da negentropia, ou seja, busca minimizar a informação mútua entre as componentes.

Por fim, é importante relatar algumas indeterminações da técnica de ACI:

(i) a ordem das componentes independentes não pode ser determinada, (ii) a variância e o sinal das CIs não podem ser estimados. A solução para (ii) consiste em assumir variância unitária para as CIs e, quanto ao sinal, diversos autores argumentam que essa indeterminação é insignificante para a maior parte dos estudos. Uma alternativa para (i) é apresentada por Yu e Chou (2009) que propõem estratégias de ordenamento das ICs baseadas nas normas euclidianas das linhas da matriz de separação \mathbf{B} . Esse reordenamento de forma decrescente garante que as

primeiras ICs sejam correspondentes aos sinais fontes com maior energia ou variação (Mutihac R. e Mutihac R.C., 2007), ou vice-versa.

ACP e ACI foram utilizadas neste artigo como duas diferentes técnicas capazes de reduzir a dimensionalidade do estudo. Essas reduções indicaram as áreas mais ativadas do cérebro sob determinados estímulos visuais, revelando informações outrora ocultas. Assim, uma comparação entre as principais características dessas duas técnicas é apresentada na seção seguinte e ajuda a compreender eventuais diferenças entre os resultados obtidos.

3.3 Breve comparação entre ACP e ACI

Análise de componentes principais e análise de componentes independentes estão intimamente ligadas à análise exploratória de dados, como compressão de dados, extração de características e padrões de reconhecimento. Essas técnicas podem ser consideradas como aproximações de aprendizagem não-supervisionada, pois (i) buscam descrever o modelo suscetível de ter formado os dados observados e; (ii) tentam preservar as informações mais importantes descartando as redundâncias (Mutihac R. e Mutihac R.C., 2007).

A análise de componentes principais elimina as dependências de até 2ª ordem utilizando apenas os 2 primeiros momentos. Essa eliminação é realizada rotacionando os eixos ortogonais que correspondem às direções de maior variação dos dados. Essa rotação produz componentes descorrelacionadas, mas não elimina as possíveis dependências de ordem superior, pois a ausência de correlação em ACP significa que as variáveis não podem ser preditas por outras utilizando um preditor linear. Porém, pode ser que ainda exista dependência não-linear entre essas variáveis (Hyvärinen et.al., 2001).

Por outro lado, a análise de componentes independentes retorna CIs ao eliminar as dependências baseando-se em momentos de grau superiores ao utilizados em ACP. As componentes independentes, diferentemente do que ocorre em ACP, não precisam ser ortogonais entre si. Em ACI os eixos indicam a posição de maior não-gaussianidade possível - o que possibilita maior flexibilidade na obtenção das CIs.

Outro fator que diferencia ACP e ACI está relacionado à ordem de obtenção das componentes. Em análise de componentes principais a ordem das CPs obtidas é sempre fixa, pois depende apenas da quantidade de explicação de cada componente em relação à variação total. Já em análise de componentes independentes a ordem das CIs não pode ser determinada, de forma que cada algoritmo retorne as componentes segundo algum critério pré-fixado.

As técnicas de ACP e ACI são utilizadas neste artigo como técnicas redutoras de dimensionalidade porém indicam as variáveis originais que melhor contribuem para a formação das componentes (principais ou independentes). Assim, é mantida a interpretação original, mas num espaço de dimensão reduzida. Por apresentarem certas singularidades, é interessante verificar o desempenho de cada uma destas técnicas quanto à capacidade de reduzir a complexidade do estudo, permitindo resultados semelhantes, ou melhores, aos obtidos quando da utilização de toda

a informação disponível na base de dados. Uma comparação entre ACP e ACI pode ser realizada a partir da comparação de resultados de diferentes técnicas de classificação, onde as técnicas de redução funcionam como uma pré-análise da investigação.

4 Identificação de regiões ativadas do cérebro

Realizar análise discriminante e classificação de sinais eletroencefalográficos (EEG) não é uma tarefa trivial. Um dos motivos para essa dificuldade é que nem todas as regiões do cérebro são ativadas durante o experimento, ou seja, muitos dos eletrodos captam sinais com pouca informação relevante para a classificação. Uma solução seria a aplicação de técnicas que identifiquem quais eletrodos são mais ativados quando um indivíduo é submetido a diferentes estímulos. As técnicas de componentes principais (ACP) e componentes independentes (ACI) foram aplicadas a fim de se verificar a eficiência na identificação de regiões mais ativadas no córtex cerebral quando indivíduos são submetidos a diferentes estímulos visuais. Após a identificação das regiões mais ativadas, utilizando cada uma das técnicas, foi utilizada a informação fornecida pelos eletrodos de cada região para proceder as análises de classificação descritas. O objetivo é comparar a taxa de classificação dos estímulos visuais por meio do uso de diferentes classificadores quando são considerados todos os eletrodos e quando são considerados apenas os eletrodos das regiões identificadas como mais ativadas por meio da ACP e ACI.

4.1 Identificação de regiões ativadas no cérebro utilizando ACP

Como visto na Seção 3.1, a primeira componente principal é a combinação linear das variáveis originais que retém a maior quantidade da variabilidade total. No caso dos dados de EEG temos componentes principais como combinações lineares dos sinais captados por cada eletrodo.

As regiões mais ativadas no cérebro são aquelas que possuem sinais com maior energia, e portanto, com maior amplitude. Como os sinais com maior amplitude são também os de maior variabilidade, pode-se supor que os eletrodos que captam os sinais das regiões mais ativadas possuem pesos maiores na primeira componente principal, já que esta componente retém maior variabilidade que as demais componentes.

4.2 Identificação de regiões ativadas no cérebro utilizando ACI

As componentes independentes estimadas pelo algoritmo FastICA são geradas em ordem aleatória (Yu e Chou, 2009). Devido a essa aleatoriedade, não é possível realizar a redução de dimensionalidade simplesmente considerando as primeiras componentes. É preciso, primeiramente, realizar o cálculo das normas euclidianas das ICs utilizando uma matriz de separação \mathbf{B} .

De acordo com Yu e Chou (2009), o quadrado da norma das fontes $\|\mathbf{s}\|^2$ pode ser decomposto na soma de dois termos: (i) o primeiro termo representando a

energia das componentes e, (ii) o segundo termo representando a correlação cruzada entre pares de sinais diferentes, i.e., a informação mútua (IM) contida em uma determinada fonte (CI). Esse segundo termo pode ser escrito como $1 - \|\mathbf{b}_k\|^2$, ou seja, a IM pode ser calculada como a diferença do quadrado da norma L_2 (norma euclidiana), referente a k -ésima linha da matriz de separação \mathbf{B} . Assim, quanto maior a norma, menor a IM contida numa específica CI e, portanto, mais próximo a componente se encontra da não-gaussianidade ideal.

Como visto na Seção 3.2 as CIs que possuem maiores normas são as que apresentam maior energia. Assim, o cálculo da norma é realizado para cada linha da matriz de separação \mathbf{B} , identificando, em seguida, as CIs com a menor e a maior norma. Uma vez que as ICs com maiores normas são as que apresentam maior energia, e seguindo o mesmo raciocínio de ACP, as normas de maior energia são também as que representam a maior variabilidade dos sinais coletados. Portanto, os eletrodos com maior representatividade nas CIs de maiores e menores normas, representados por ACI_{128} e ACI_1 respectivamente, são os escolhidos para integrar o cálculo das componentes.

4.3 Estimação da taxa de classificação correta utilizando validação cruzada

O banco de dados (já descrito na Seção 2) consiste em 40 sinais provenientes da visualização em ordem aleatória de 10 imagens repetidas, de forma aleatória, 4 vezes cada uma.

Neste artigo, utilizamos as técnicas de análise de discriminantes linear (ADL), análise de discriminantes quadrática (ADQ) e Máquinas de Vetores de Suporte Vetorial (SVM). A análise discriminante linear (ADL) busca encontrar a combinação linear das variáveis que melhor separam duas classes (Johnson e Wichern, 2007). A análise discriminante quadrática (ADQ) procura separar as classes a partir da combinação linear das variáveis em estudo juntamente com todos os produtos dessas variáveis tomadas duas a duas (Johnson e Wichern, 2007). Em problemas de classificação, a técnica de Máquinas de Vetores de Suporte (Vapnik, 1996) separa duas classes em um conjunto de dados por um hiperplano ótimo que maximiza a margem de separação entre as classes. As técnicas ADL, ADQ e MSV com os Kernels linear e radial foram utilizadas para calcular os discriminantes dos sinais relativos aos pares de imagens abstratas contra imagens matemáticas (Figura 1), i.e., comparação de cada um dos dois primeiros estímulos visuais da Figura 1 contra os demais estímulos, formando um total de 16 combinações de imagens. Para estimar a taxa de classificação correta utilizou-se, para cada par de estímulos comparados, uma validação cruzada de acordo com o seguinte algoritmo:

1. Inicie i , onde $i = 1, 2, 3, 4$ representam as 4 repetições ou número de vezes que cada imagem é mostrada;
2. Utilize as demais repetições para o cálculo do discriminante;
3. Avalie a taxa de acerto com o sinal retirado no passo 2;

4. Se $i < 4$, faça $i \leftarrow i + 1$ e volte ao passo 2;
5. Estime a taxa de classificação correta total, i.e., número de sinais corretamente classificados em todas as comparações dividido pelo número total de comparações.

5 Resultados com dados reais

A análise de componentes principais e a análise de componentes independentes foram utilizadas para identificar as regiões ativadas no cérebro com a apresentação dos estímulos visuais descritos anteriormente. Mais precisamente, utilizou-se os eletrodos referentes às áreas ativadas pela primeira componente principal e pelas componentes independentes de maior norma euclidiana. A Figura 2 mostra, respectivamente, as áreas ativadas pela primeira CP e pela CI de maior norma. Em (a) a região identificada está ligada ao planejamento de ações, movimento e pensamento abstrato (von Borries et. al., 2010). Em (b), a área identificada está relacionada a área do cérebro responsável pela visão.




Figura 2 - Representação de áreas ativadas utilizando (a) a primeira Componente Principal e (b) a Componente Independente de maior norma euclidiana.

Para verificar se as áreas identificadas por ACP e ACI são realmente importantes para a análise de EEG, realizou-se uma comparação entre o desempenho de ambas as técnicas na redução dos dados, utilizando Análise Discriminante Linear (ADL), Análise Discriminante Quadrática (ADQ) e Máquinas de Vetores de Suporte (SVM) com núcleos lineares (MSV Linear) e radial (MSV Radial) como técnicas de classificação para a identificação dos estímulos visuais.

Foram calculadas as taxas de classificação correta para diversos conjuntos de eletrodos. Inicialmente calculou-se as taxas de classificação utilizando todos os 128 eletrodos. Em seguida procedeu-se a seleção de eletrodos utilizando a primeira componente principal (ACP), a componente independente com menor norma (ACI_1) e a componente independente com maior norma (ACI_{128}). Os conjuntos de eletrodos selecionados por ACP e ACI foram restringidos a 32, 20, 15 e 10 eletrodos.

A Tabela 1 apresenta todas as taxas de classificação para as diferentes quantidades de eletrodos utilizadas em cada uma das técnicas em estudo. A melhor taxa de classificação considerando todos os 128 eletrodos (89%) foi obtida ao utilizar ADQ. Em seguida aparece MSV Radial com 72,7% de acerto. Ou seja, os discriminantes não lineares parecem mais adequados que os lineares, sempre obtendo taxas de classificação correta mais elevadas.

Tabela 1 - Taxas de classificação utilizando diferentes procedimentos

N° Eletrodos	Técnica de Redução	Taxa			
		ADL	ADQ	MSV Linear	MSV Radial
128	-	0.648	0.891	0.547	0.727
32	ACP	0.680	0.891	0.680	0.836
32	ACI(1)	0.641	0.852	0.648	0.742
32	ACI(128)	0.656	0.867	0.703	0.727
20	ACP	0.555	0.930	0.586	0.750
20	ACI(1)	0.648	0.867	0.648	0.742
20	ACI(128)	0.695	0.914	0.734	0.836
15	ACP	0.507	0.906	0.539	0.750
15	ACI(1)	0.617	0.828	0.609	0.703
15	ACI(128)	0.703	0.914	0.734	0.844
10	ACP	0.586	0.930	0.586	0.703
10	ACI(1)	0.547	0.695	0.555	0.625
10	ACI(128)	0.687	0.906	0.703	0.734

Podemos observar na Figura 3 que, em média, considerando todos os eletrodos (128), as taxas de classificação obtiveram os piores resultados. As melhores taxas foram alcançadas para o grupo de 20 eletrodos, seguidas bem de perto pelo grupo de 15 eletrodos, embora a variabilidade no grupo de 20 eletrodos seja menor que a no de 15 eletrodos.

As taxas obtidas utilizando-se eletrodos selecionados da componente independente de maior norma foram sempre superiores às taxas obtidas utilizando-se eletrodos selecionados da componente independente de menor norma, exceto em uma dentre as 16 combinações. Comparando as taxas conseguidas utilizando os eletrodos selecionados pela primeira componente principal ou pela componente independente de maior norma não é possível chegar a uma conclusão sobre o melhor método de seleção, pois, embora na maior parte dos casos a taxa utilizando seleção por ACI (maior norma) seja superior, a melhor taxa obtida (93%) foi alcançada utilizando seleção pela ACP. A Figura 4 mostra as taxas de classificação para cada tipo de seleção de eletrodos.

Dentre as técnicas empregadas, a ADQ foi a que, no geral, apresentou as maiores taxas de classificação correta (Figura 5 (a)). Para essa técnica em especial, a redução de dimensionalidade por ACP foi a que exibiu melhores resultados, exceto para o grupo de 15 eletrodos, onde as CIs de maiores normas exibiram, para todas as 4 técnicas de classificação, as melhores taxas conforme observado na Figura 5 (b).




Figura 3 - Gráficos Box Plot representando taxas de classificação para diferentes quantidades de eletrodos.




Figura 4 - Gráficos Box Plot representando taxas de classificação para as diferentes formas de seleção dos eletrodos

O fato mais relevante, portanto, é que utilizando a análise de componentes principais ou a análise de componentes independentes é possível aumentar a taxa de classificação correta empregando um menor número de eletrodos. Ou seja, provavelmente alguns eletrodos estavam influenciando negativamente a performance dos classificadores ao captar sinais de regiões não ativadas no cérebro. Entretanto, não sabemos se os eletrodos mais informativos são os mesmos em todas as situações. Isto poderá ser avaliado em estudos futuros.

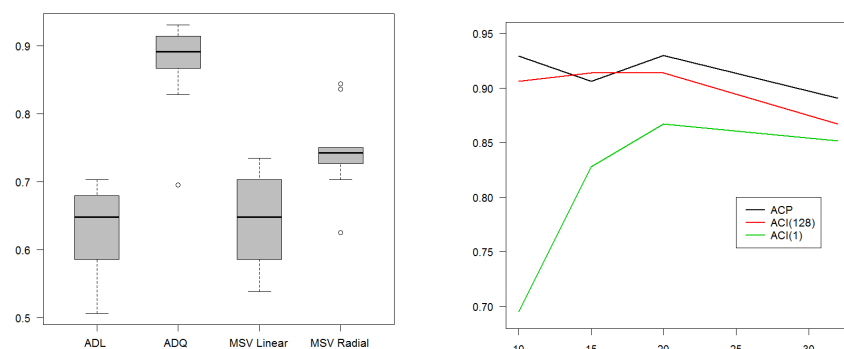


Figura 5 - Representação do desempenho das 4 diferentes técnicas de classificação utilizadas (figura à esquerda); Desempenho das técnicas de seleção considerando apenas a QDA (figura à direita).

Conclusões

A análise de componentes principais e a análise de componentes independentes parecem identificar de maneira satisfatória as áreas ativadas no cérebro durante a apresentação dos estímulos visuais. Apesar das áreas identificadas por ACP e por ACI serem diferentes, os resultados obtidos da análise de classificação mostraram excelente desempenho para as duas técnicas na redução do número de eletrodos utilizados ao classificar estímulos visuais com sinais de EEG. As técnicas empregadas permitem que a redução seja feita para cada estudo e indivíduo de maneira automática.

Como o cérebro humano possui características individuais, trabalhos futuros deverão verificar se, em geral, os resultados alcançados se mantêm - utilizando semelhante metodologia - para sinais provenientes de indivíduos diferentes.

Agradecimentos

Os autores agradecem as excelentes sugestões dos pareceristas que muito contribuíram para a melhoria da qualidade deste texto e a Dra. Andréa Márcia M.A. Coutinho da Universidade Católica de Brasília pela cuidadosa revisão de português. Agradecem ainda o suporte da *National Science Foundation* (NSF) pelo investimento no *Multi-Sensing-Processing and Learning Laboratory* (MSPL) da Universidade do Texas em El Paso (UTEP) e ao SAS Institute Brasil pela parceria acadêmica com o departamento de Estatística da Universidade de Brasília (UnB).

VON BORRIES, G.F.; ROCHA, L.C.S.; COUTINHO, M.; VON BORRIES, R.F. Identification of Brain-Generated activity with EEG using visual stimuli. *Rev. Bras. Biom.*, São Paulo, v.31, n.1, p.28-42, 2013.

- **ABSTRACT:** Recent techniques in digital signal processing allow detection of different kinds of mental activity from brain-generated biopotentials. Electroencephalograph (EEG) methods, as opposed to invasive measurements, have the advantage of requiring only surface biopotentials to be acquired, and are therefore more suitable for regular use of Human Machine Interface equipment in application such as classification of thought patterns for machine control by persons with motor disabilities. This work uses Principal Component Analysis (PCA) and Independent Component Analysis (ICA) of EEG signals to investigate areas (electrodes) most activated when brain is submitted to a sequence of visual stimuli. The main difference is to use of original electrodes from information given by ICA and PCA components and not the obtained components. The data was collected in the Multi-Sensing-Processing and Learning Laboratory at UTEP, using a 128-electrode acquisition system. EEG data reduction and source identification allow one to understand brain activity during different tasks and to reduce the number of dimensions in classification procedures. Using Linear Discriminant Analysis (LDA), Quadratic Discriminant Analysis (QDA) and Support Vector Machine (SVM) procedures for classification, it was verified that classification rates increase after selection of electrodes using PCA and ICA. However, there is no significant difference in classification rates when using PCA or ICA, even though the electrodes identified as most activated by each techniques are different. By applying this technique, we expect to improve classification of different tasks with respect to usual classification techniques applied to raw data and to better understand brain activation by visual stimuli.
- **KEYWORDS:** Principal component analysis; independent component analysis; electroencefalography; visual stimuli; classification.

Referências

- FRONDANA, I. M. *Classificação de biopotenciais via cadeias de Markov ocultas*. 2012. Dissertação (Mestrado em Estatística). Universidade de Brasília, 2012.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The elements of statistical learning: data mining, inference and prediction*. 2.ed., Stanford: Springer, 2009.
- HYVÄRINEN, A.; OJA, E. Independent component analysis: algorithms and applications. *Neural Netw.*, Kidlington, v.13, n.4/5, p.1-13, 2000.
- HYVÄRINEN, A.; HURRI, J.; HOYER, P. O. *Natural image statistics. a probabilist approach to early computational vision*. Amsterdam: Springer, 2009. 448p.
- HYVÄRINEN, A.; KARHUNEN, J.; OJA, E. *Independent component analysis*. New York: John Wiley & Son, 2001.
- IZENMAN, A. J. *Modern multivariate statistical techniques: regression, classification, and manifold learning*. Amsterdam: Springer, 2008.
- JOHNSON, R. A.; WICHERN, D. W. *Applied multivariate statistical analysis*. 6.ed. New Jersey: Pearson Prentice Hall, 2007. 800p.

- LOTTE, F.; CONGEDO, M.; LÉCUYER, A.; LAMARCHE, F.; ARNALDI, B. A review of classification algorithms for EEG-based brain-computer interfaces. *J. Neural Eng.*, Bristol, v.6, n.2, p.r1-r13, 2007.
- MAHAJAN, K.; VARGANTWAR, M. R. e RAJPUT, S. M. Classification of EEG using PCA, ICA and Neural Network. *Int. J. Eng. Adv. Technol. (IJEAT)*, v.1, p.80-83, 2011.
- MUTIHAC, R.; MUTIHAC, R.C. A Comparative study of independent component analysis algorithms for electroencephalography. *Rom. Rep. Phys.*, Bucarest, v.59, n.3, p.831-860, 2007.
- SÖRNMO, L.; LAGUNA, P. *Bioelectrical signal processing in cardiac and neurological applications*. Amsterdam: Elsevier Academic Press, 2005. 688p.
- STONE, J. V. *Independent component analysis*. a tutorial introduction. Cambridge: The MIT Press, 2004. 30p.
- SUBASI, A.; GURSOY, M. I. EEG signal classification using PCA, ICA, LDA and support vector machines. *textitExpert Syst. Appl.*, New York, v.37, n.12, p.8659-8666, 2010.
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern recognition*. 3.ed., San Diego: Elsevier, 2006. 984p.
- VAPNIK, V. *The nature of statistical learning theory*. New York: Willey, 1996. 314p.
- VIGÁRIO, R.; SÄRELÄ, J.; JOUSMÄKI, V.; HÄMÄLÄINEN, M.; OJA, E. Independent component approach to the analysis of EEG and MEG recordings. *IEEE Trans. Biomed. Eng.*, Piscataway, v.47, n.5, p.589-593, 2000.
- VON BORRIES, G. F.; COUTINHO, M.; VON BORRIES, R. F.; MIOSSO, C. J. *Principal component analysis of brain-generated biopotencial measurements*. In: CONGRESO LATINOAMERICANO DE SOCIEDADES DE ESTADÍSTICA, 9., 2010. *Resumenes ... Vinha del Mar - Chile*. 2010.
- YU, S. N.; CHOU, K. T. Selection of significant independent components for ECG beat classification. *Expert Syst. Appl.*, New York, v.36, n.2, p.2088-2096, 2009.

Recebido em 26.05.2013.

Aprovado após revisão em 09.09.2013.