

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA  
UNIDADE ACADÊMICA DE ENGENHARIA ELÉTRICA



TRABALHO DE CONCLUSÃO DE CURSO

*Separação Cega de Fontes Aplicada à Sinais de Áudio e  
Imagem*

**Camila de Araújo Souto**

**Orientador: Prof. Edmar Candeia Gurjão**

Campina Grande - PB  
Junho de 2011

# Separação Cega de Fontes Aplicada à Sinais de Áudio e Imagem

Análise de Componentes Independentes

Camila de Araújo Souto

Trabalho de Conclusão de Curso apresentado à Unidade Acadêmica de Engenharia Elétrica como parte dos requisitos para obtenção do título de Engenheiro Eletricista.

Orientador: Prof. Edmar Candeia Gurjão

Campina Grande - PB  
Junho de 2011

# Separação Cega de Fontes Aplicada à Sinais de Áudio e Imagem

Análise de Componentes Independentes

Camila de Araújo Souto

Trabalho de Conclusão de Curso apresentado à Unidade Acadêmica de Engenharia Elétrica como parte dos requisitos para obtenção do título de Engenheiro Eletricista.

Edmar Candeia Gurjão, Dr., UFCG  
Orientador

Professor da banca, UFCG  
Componente da Banca

Campina Grande - PB  
Junho de 2011

# Agradecimentos

Agradeço ao Professor Edmar Candeia Gurjão pela orientação neste trabalho e pelos ensinamentos desde minha primeira disciplina no curso de Engenharia Elétrica.

Ao Rosa pela ajuda com o material para a realização deste trabalho.

Aos demais professores do curso de Engenharia Elétrica da UFCG pelas lições teóricas e de vida.

Aos funcionários deste curso por todo o apoio e carinho.

Aos colegas e amigos de curso que me ajudaram a chegar ao final com muito companheirismo e bom humor.

A Júlio César, meu noivo, pela ajuda com o tema do TCC e por todo apoio ao longo do curso.

*À Papai,  
Mamãe,  
e Mamá.*

# Resumo

O problema de superposição de sinais é estudado desde o princípio das telecomunicações, seja na tentativa de minimizar o efeito de ruído, seja simplesmente para isolar uma fonte de referência. Este trabalho tem como finalidade estudar a separação de fontes onde não existe qualquer informação sobre como se deu a misturas das mesmas, a chamada separação cega de fontes. Aqui será analisado o método para a separação de fontes independentes misturadas linearmente através da análise de componentes independentes. Por fim, descreve-se o algoritmo *fastICA* e é avaliada sua aplicação para sinais de áudio e de imagens.

# Abstract

The problem of overlapped signals has been studied since the very early days of telecommunications, either to minimize the effects of noise, or simply to isolate a reference source. This work aims to study the source separation when there is no information of how those signals were mixed, known as blind source separation process. It will be analyzed the method for the separation of linear mixtures of independent sources through independent component analysis. Finally, it will be described the *FastICA* algorithm and evaluated its application to audio signals and images.

# Lista de Figuras

2.1	Os sinais em azul de naturezas distintas são misturados linearmente entre si, gerando os sinais observados, em vermelho, e a baixo estão os sinais já serapados utilizando BSS, em preto. . . . .	4
3.1	Em [12]. As amostras de sinais da MEG, contendo artefatos produzidos através do movimento muscular voluntário, piscar e morder. . . . .	8
3.2	Em [12]. Nove componentes independentes obtidas a partir dos dados encontrados na MEG. Para cada componente são apresentados os padrões de campos gerados pelas mesmas nos lados esquerdo, direito e na parte de trás .	9
3.3	Em [9]. Sistema proposto para utilização de ICA no problema de EMI . . . .	10
3.4	Em azul os sinais antes da mistura; À direita, em vermelho, os sinais misturados; Em verde os sinais após sofrerem a tranformação linear ou branqueados.	12
3.5	A soma ou mistura linear de variáveis aleatórias independentes tente a uma variável com distribuição gaussiana . . . . .	14
3.6	Algoritmo fastICA . . . . .	16
3.7	De cima para baixo: Os dois sinais originais(azul), seguidos pelos dois sinais misturados(vermelho), e por fim, os dois sinais separados(preto) . . . . .	17
4.1	Histograma das amostras do sinal de áudio captado em um ambiente(esquerda) e de uma sirene(direita) . . . . .	19
4.2	Sinais de áudio misturados . . . . .	19
4.3	Componentes independentes separadss . . . . .	20
4.4	Imagens originais, antes da mistura . . . . .	20
4.5	Imagens misturadas linearmente a) e b) e separadas c) e d) através de análise de componentes independentes . . . . .	21

# Glossário

- BSE - Extração Cega de Fontes  
*Blind Source Extraction*
- BSD - Desconvolução Cega de Fontes  
*Blind Source Deconvolution*
- BSS - Separação Cega de Fontes  
*Blind Source Separation*
- EMI - Interferência Eletromagnética  
*Electromagnetic Interference*
- ICA - Análise de Componentes Independentes  
*Independent Component Analysis*
- MEG - Magnetoencefalografia

# Sumário

Resumo	v
Abstract	vi
Lista de Figuras	vii
Glossário	viii
<b>1 Introdução</b>	<b>1</b>
<b>2 Separação Cega de Fontes</b>	<b>3</b>
<b>3 Análise por Componentes Independentes</b>	<b>6</b>
3.1 Aplicações . . . . .	6
3.1.1 Separação de sinais de Ondas Cerebrais . . . . .	7
3.1.2 <i>Cocktail Party</i> . . . . .	7
3.1.3 Estimacão de Sinais Eletromagnéticos . . . . .	8
3.2 Branqueamento . . . . .	8
3.3 Determinacão da Matriz de Separação $W$ . . . . .	13
3.3.1 Critério da Não-Gaussianidade . . . . .	13
3.4 Algoritmo . . . . .	16
3.5 Resultados Iniciais . . . . .	16
<b>4 Simulações</b>	<b>18</b>
4.1 Separação de Áudio . . . . .	18
4.2 Separação de Imagens . . . . .	18

5 Conclusão	22
Apêndice A - fastICA.m	22
Apêndice B - teste_audio.m	25
Apêndice C - teste_imagem.m	26

# Capítulo 1

## Introdução

Em meados dos anos 80 a técnica da separação de fontes através de análise de componentes independentes foi apresentada por J. Héroult, C. Jutten, e B. Ans em estudos de impulsos nervosos musculares, citado por Jutten em [7], onde dois sinais  $x_1$  e  $x_2$  eram obtidos a partir de contrações musculares e seriam separados nos sinais  $s_1$  e  $s_2$  que indicariam a posição angular e velocidade do movimento de uma articulação. Desde então muitos algoritmos foram propostos para solução de problemas relacionados com separação de sinais independentes, muitos deles restritos a poucas aplicações. Graças às fortes ligações entre os critérios estatísticos de otimização e os algoritmos desenvolvidos, estes foram aprimorados, tornando-se mais confiáveis, robustos e abrangentes.

Em 1997 A. Hyvärinen and E. Oja em *A fast fixed-point algorithm for independent component analysis* [5] propuseram o *fastICA* um algoritmo capaz de separar componentes independentes a partir da maximização da não-gaussianidade através da negentropia, curtose ou critério da máxima verossimilhança. Além da rápida convergência, o algoritmo funciona estimando as componentes independentes apenas pela utilização das amostras do sinal resultante da mistura, sem qualquer necessidade de parâmetros adicionais. Talvez por isso, esse algoritmo têm sido largamente utilizado e aplicado em diversos estudos para separação de sinais independentes.

Os sinais serapados, em sua grande maioria, são aqueles obtidos através de sensores que podem estar avariados ou sofrer interferência de outra fonte, além da observada. A mistura destes sinais pode ser instantânea ou convolutiva, linear ou não-linear. Neste trabalho será estudada a aplicação do algoritmo *fastICA* através da maximização da negentropia, para misturas instantâneas e lineares. O algoritmo foi aplicado à sinais de voz e imagens.

No capítulo 2 será explicado o conceito de separação cega de fonte e seus diferentes métodos. No capítulo 3 será introduzido o conceito de análise de componentes independentes, exemplos onde este método é aplicado, as etapas do processo e uma simulação experimental com sinais com distribuição uniforme misturados. Por fim, no capítulo 4 serão apresentados resultados obtidos na aplicação do método para sinais de áudio e de imagens.

# Capítulo 2

## Separação Cega de Fontes

Imagine uma sala de aula na qual o professor leciona ao mesmo tempo em que se escuta o ruído externo dos corredores e do ar-condicionado, formando um único sinal composto da mistura dos três sinais listados. Nesse contexto, deseja-se utilizar o sinal composto para separar o sinal de interesse, a voz do professor. Por volta de 1982 Bernard Ans, Jeanny Herault, e Christian Jutten formularam o problema sobre Separação Cega de Fontes (*Blind Source Separation - BSS*) na modelagem por redes neurais. Com os estudos feitos para a solução de tal problema, tornou-se possível separar fontes distintas a partir de misturas de sinais, sem o conhecimento de como as mesmas se deram ou qual a natureza dos sinais em questão, daí o termo *cega*. A Figura 2.1 mostra dois sinais de características distintas misturados linearmente e separados através da separação cega de fontes.

A formulação do problema de BSS é feita considerando sinais independentes emitidos por fontes físicas distintas  $s_1(t), s_2(t), \dots, s_N(t)$ . Sensores ou receptores são colocados em posições diferentes de tal forma que os sinais observados  $x_1(t), x_2(t) \dots x_M(t)$  sejam a mistura de todos  $s_i$ 's e que estes sejam captados com pesos diferentes, de tal forma que para  $N=3$  e  $M=3$ :

$$\begin{aligned}x_1(t) &= a_{11}s_1(t) + a_{12}s_2(t) + a_{13}s_3(t) \\x_2(t) &= a_{21}s_1(t) + a_{22}s_2(t) + a_{23}s_3(t) \\x_3(t) &= a_{31}s_1(t) + a_{32}s_2(t) + a_{33}s_3(t)\end{aligned}\tag{2.1}$$

A Separação Cega de Fontes consiste em encontrar a matriz de inversão  $W$ , tal que:

$$y_1(t) = w_{11}x_1(t) + w_{12}x_2(t) + w_{13}x_3(t)$$

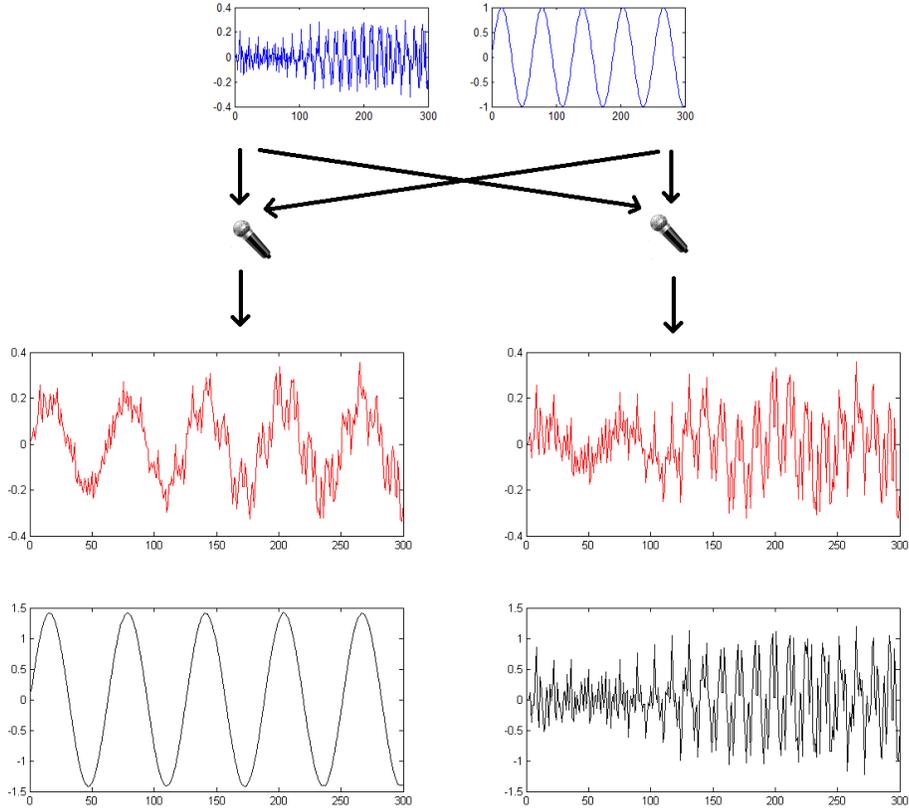


Figura 2.1: Os sinais em azul de naturezas distintas são misturados linearmente entre si, gerando os sinais observados, em vermelho, e a baixo estão os sinais já serapados utilizando BSS, em preto.

$$y_2(t) = w_{21}x_1(t) + w_{22}x_2(t) + w_{23}x_3(t) \quad (2.2)$$

$$y_3(t) = w_{31}x_1(t) + w_{32}x_2(t) + w_{33}x_3(t)$$

Onde o  $y_i(t)$  é a  $i$ -ésima amostra estimada do sinal  $s(t)$ .

Para a estimação de fontes em geral existem vários métodos. Um deles é a Extração Cega de Fontes (*BSE - Blind Source Extraction*) que consiste em extrair de uma série de sinais apenas aqueles de interesse. Na BSE os sinais podem ser extraídos, ou separados, em uma ordem específica de acordo com as características estatísticas das fontes. Porém, estes são extraídos um a um demandando um grande esforço computacional.

Outro método é a Desconvolução Cega de Múltiplos Usuários (*BSD - Blind Signal Deconvolution*). Na desconvolução cega apenas o sinal de entrada é conhecido e os sinais das

fontes e sistema de convolução devem ser estimados. Como o nome sugere, considera-se que o sinal observado em um dado instante foi obtido a partir da convolução do sinal da fonte com uma matriz contendo os coeficientes da mistura e que para a desconvolução é necessário o conhecimento estatístico das fontes. Esta técnica é baseada em estatísticas de ordem superior e muitas idéias utilizadas aqui foram adaptadas aos estudo de BSS utilizando Análise por Componentes Independentes.

Neste caso analisaremos esta última técnica onde as únicas informações que possuímos sobre o sistema em questão, além das amostras dos sinais misturados, são que as fontes são estatisticamente independentes e não-gaussianas.

No próximo capítulo além da introdução à análise de componentes independentes, serão apresentadas algumas aplicações e o algoritmo escolhido para implementar este método.

# Capítulo 3

## Análise por Componentes Independentes

A análise por componentes independentes (*Independent Component Analysis - ICA*) consiste em, a partir da idéia de BSS, estimar a matriz  $A$ , apresentada no capítulo anterior na equação 2.1 como sendo a matriz de mistura linear, e conseqüentemente os sinais  $s_i$ 's, levando em conta as restrições básicas no sinal da fonte. Como já dito anteriormente, na separação cega de fontes baseada em ICA as fontes devem ser estatisticamente independentes, ou o mais independentes possível, o que pode ser medido com métodos apresentados adiante na seção 3.1.1. A mistura destas componentes pode ocorrer de formas variadas e depender de uma série de variáveis. A mistura pode ser linear, ou seja, atender ao princípio da superposição. Caso contrário o sistema de mistura é considerado não-linear. O sistema pode ser convolutivo, onde uma dada amostra em um certo instante depende de amostras anteriores. Ou ser um sistema instantâneo e depender das amostras obtidas apenas naquele instante. Neste trabalho serão consideradas misturas lineares e instantâneas. Além disso, consideraremos que o número de fontes é igual ao número de sinais observados  $x_i(t)$ ,  $N$  igual a  $M$ , nas equações 2.1 e 2.2. Veremos mais a frente neste trabalho que para estimar sinais através da ICA é necessário que todas as fontes, além de independentes, sejam não-gaussianas.

### 3.1 Aplicações

Existe uma vasta gama de aplicações que utilizam algoritmos baseados em análise por componentes independentes. Estas vão de análise de dados geofísicos ou financeiros a processa-

mento de sinais biomédicos. Aqui veremos alguns dos exemplos mais conhecidos e citados na literatura.

### 3.1.1 Separação de sinais de Ondas Cerebrais

Magnetoencefalografia ou simplesmente MEG é uma técnica não invasiva utilizada para medir a atividade cerebral. Quando utilizado para concepção de diagnosticos é necessária uma precisão muito grande nos sinais captados. Porém, junto com o sinal muitas vezes são captados os chamados artefatos, sinais referentes ao piscar dos olhos, mordida, ciclos cardíacos ou mesmo avaria no sensor.

Em alguns momentos a amplitude dos artefatos pode ser significativamente maior que a amplitude do sinal estudado, podendo assim camuflar patologias ou confundir o operador. Em [12] estudos foram feitos utilizando o método de separação de fontes através do ICA para separar as componentes independentes dos sinais essenciais e dos artefatos, considerando que tais sinais são processos anatomicamente e psicologicamente independentes. Após posicionados doze eletrodos para medição da atividades nos lobos frontais, temporais e occipitais, foi pedido ao paciente examinado que piscasse os olhos, em seguida que movesse um músculo e depois que morderse. Os sinais observados e nove componentes independentes encontradas são mostradas nas Figuras 3.1 e 3.2.

### 3.1.2 *Cocktail Party*

Talvez o exemplo mais clássico, onde várias pessoas conversam ao mesmo tempo em um ambiente fechado, além das interferências ocasionadas, por exemplo, por multipercusos ou música de fundo. O cérebro humano é capaz, através do seu complexo sistema nervoso, distinguir de onde cada som é originado. O problema conhecido como *Cocktail Party* [3][4][8][11] vem para responder o seguinte questionamento: Seria possível recriar artificialmente tal capacidade humana?

A separação cega de fontes, através da análise por componentes independentes apareceu como uma das melhores alternativas à resolução desta questão.

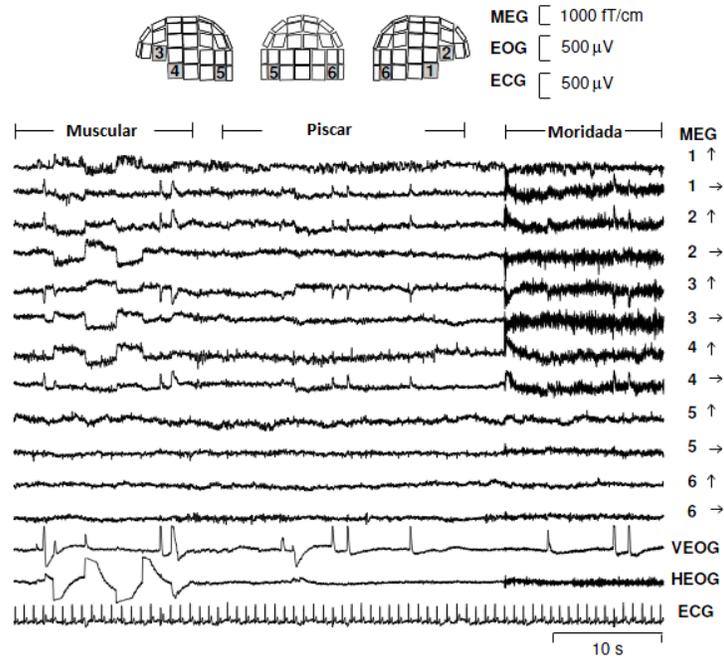


Figura 3.1: Em [12]. As amostras de sinais da MEG, contendo artefatos produzidos através do movimento muscular voluntário, piscar e morder.

### 3.1.3 Estimação de Sinais Eletromagnéticos

A presença de interferência eletromagnética (*Electromagnetic Interference - EMI*) em linhas de transmissão usadas em telecomunicações é um problema agravado com o aumento das taxas utilizadas. O primeiro passo para solução deste problema é a identificação da fonte da EMI e então aplicação de filtros ou outros artifícios de forma a minimizar o efeito desta interferência. Algoritmos utilizando ICA se mostraram eficientes na estimação de múltiplas interferências em um conjunto de linhas de transmissão, como exemplifica a Figura 3.3. No experimento dois geradores de sinais foram conectados a um cabo de par trançado de 500m, para verificar o efeito de *cross-talk*. Por fim o sinal de saída foi medido na outra extremidade da linha.

## 3.2 Branqueamento

A descorrelação entre os sinais, não é uma condição suficiente, porém, necessária para obtenção de elementos independentes. Assim, a primeira etapa para a separação cega de

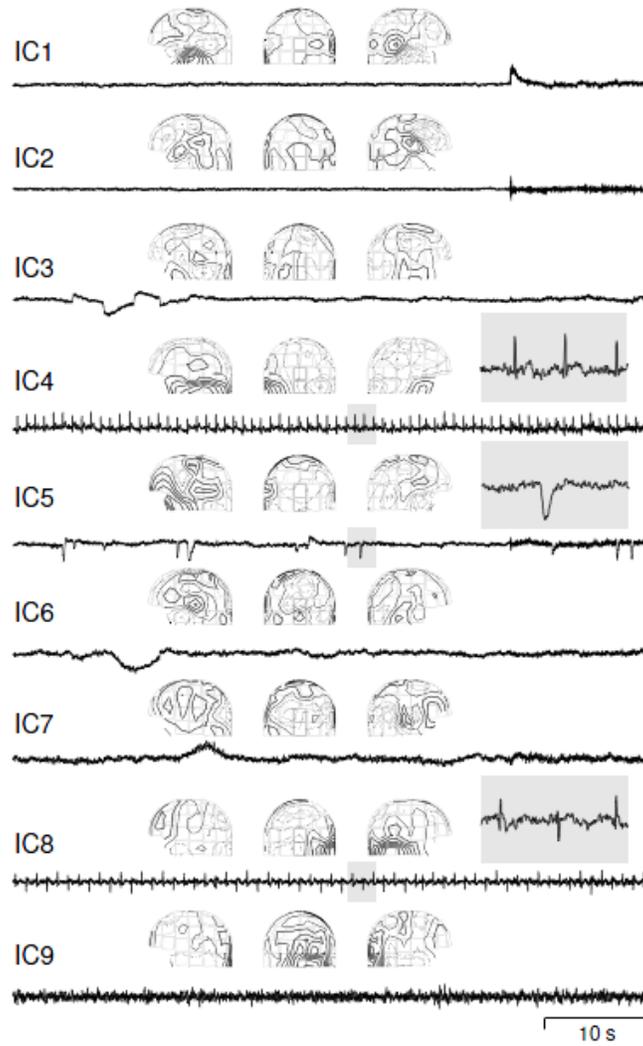


Figura 3.2: Em [12]. Nove componentes independentes obtidas a partir dos dados encontrados na MEG. Para cada componente são apresentados os padrões de campos gerados pelas mesmas nos lados esquerdo, direito e na parte de trás

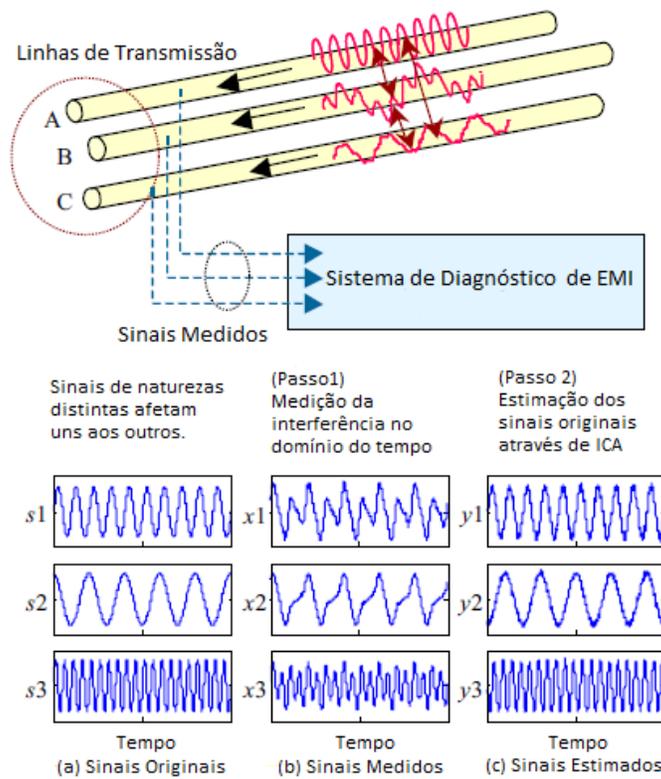


Figura 3.3: Em [9]. Sistema proposto para utilização de ICA no problema de EMI

fonte, a partir da ICA é o chamado branqueamento, que descorrelaciona as componentes do vetor  $\mathbf{s}$ .

Sem perda de generalidade, é possível considerar que tanto a mistura quanto as componentes independentes possuem média nula e variância unitária. O que simplificará bastante a teoria e o algoritmo. Como de fato as variáveis não possuem média zero, para isso as amostras devem ser centralizadas, ou seja, de cada amostra subtrai-se o valor médio do sinal. A centralização dos dados é o primeiro passo para o branqueamento. Por simplicidade, o valor médio é considerado a média aritmética das amostras.

Define-se a matriz de transformação  $T$ , que relaciona o sinal observado  $x(k)$  e o sinal branqueado  $\bar{x}(k)$ .

$$\bar{x}(k) = Tx(k) \quad (3.1)$$

Para tanto, considere a matriz de autocorrelação do sinal observado:

$$R_x = E\{x(k)x(k)^T\} = AR_{\bar{x}}A^T = AA^T \quad (3.2)$$

Onde  $R_{\bar{x}}$  é matriz da autocorrelação do sinal branqueado, que, evidentemente é a matriz identidade, já que os dados estarão descorrelacionados e possuem variância unitária.

Após o branqueamento a matriz de autocorrelação do sinal é:

$$R_{\bar{x}} = E\{\bar{x}(k)\bar{x}(k)^T\} = WR_xW^T \quad (3.3)$$

Se  $W$  pode ser escrito como:

$$W = ED^{-1/2}E^T \quad (3.4)$$

uma solução pode ser encontrada através da decomposição em valores utilizando:

$$R_x = E\{x(k)x(k)^T\} = EDE^T \quad (3.5)$$

Onde a matriz  $E$ , composta pelos autovetores de  $R_x$ ; e a matriz diagonal contendo os autovalores de  $R_x$  denominada por  $D$ . Por fim:

$$T = D^{-1/2}E^T \quad (3.6)$$

**Exemplo 1** A Figura 3.4 mostra as etapas de mistura e branqueamento para dois sinais senoidais.

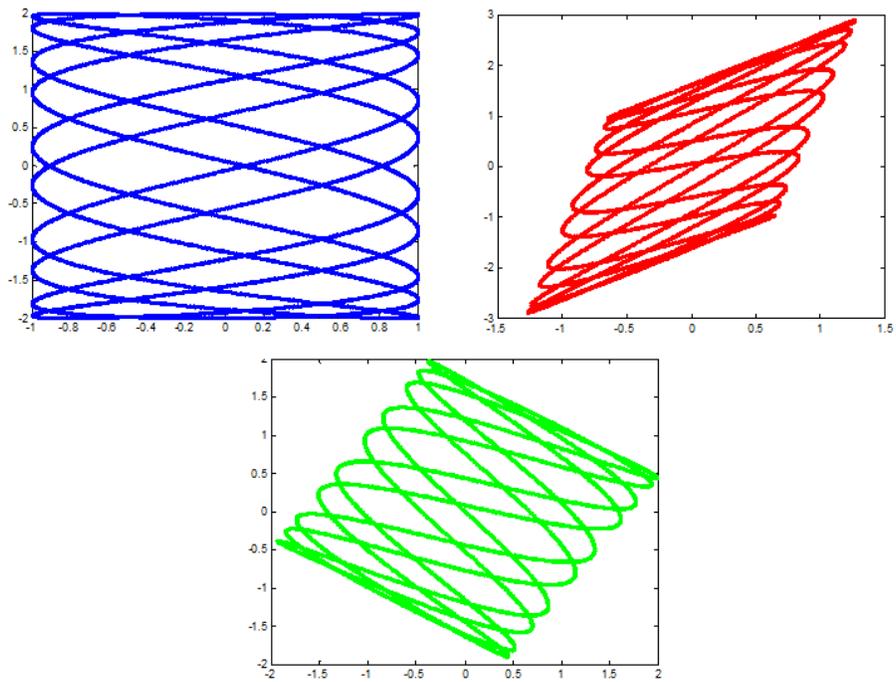


Figura 3.4: Em azul os sinais antes da mistura; À direita, em vermelho, os sinais misturados; Em verde os sinais após sofrerem a transformação linear ou branqueados.

### 3.3 Determinação da Matriz de Separação $W$

Considerando a matriz de transformação  $QT$ , para qualquer matriz ortogonal  $Q$ , percebe-se que  $R_{\bar{x}}$  ainda é igual à identidade. Ou seja, para qualquer matriz ortogonal  $Q$ , poderão ser obtidos dados descorrelacionados entre si. Assim, é possível concluir que a recuperação das fontes exclusivamente a partir da correlação apresenta uma indeterminação relacionada a  $Q$ . Porém, sendo a descorrelação uma condição necessária à independência, restringe-se o espaço das matrizes possíveis  $Q$ , tal que separe as componentes independentes do sistema.

No Exemplo 1 é possível ver geometricamente a ação do branqueamento, onde os sinais são misturados linearmente por uma matriz desconhecida e, apesar do branqueamento recuperar as escalas da fonte, não é possível recuperar a rotação, efeito da indeterminação referente a matriz ortogonal.

Considerando fontes gaussianas, que podem ser caracterizadas apenas por média e variância, é possível tornar a mistura das mesmas independente apenas através da descorrelação. Como o branqueamento da mistura não possui solução única, não será possível determinar a matriz ortogonal de separação dos sinais. Estatísticas de ordem superior são essenciais na separação de fontes utilizando componentes independentes. Conseqüentemente, sinais gaussianos, cuja definição não vai além de estatísticas de segunda ordem, não poderão ser separados.

#### 3.3.1 Critério da Não-Gaussianidade

Como dito anteriormente, para que a separação de fontes através de ICA seja possível é necessário que as fontes sejam não-gaussianas, munido desta informação, utiliza-se o teorema central do limite como uma forma de determinar a matriz de inversão  $W$ .

O **teorema central do limite** afirma que a soma de variáveis aleatórias independentes tende a uma variável com distribuição gaussiana quando o número de fontes tende a infinito. Ou seja, quanto mais sinais misturados, mais a curva da função densidade de probabilidade da mistura se assemelha a uma gaussiana. Assim, quanto menos gaussiana for a variável aleatória, esta pode ser considerada "mais independente" de qualquer outra variável aleatória em questão. Conseqüentemente, Para reverter o processo de mistura, e obter sinais o mais independente possível uns dos outros, deve-se maximizar a não-gaussianidade dos sinais das fontes.

Na literatura são apresentados alguns critérios que avaliam a gaussianidade de uma variável. Um deles é a curtose que, apesar da simplicidade, é baseada em estatística de

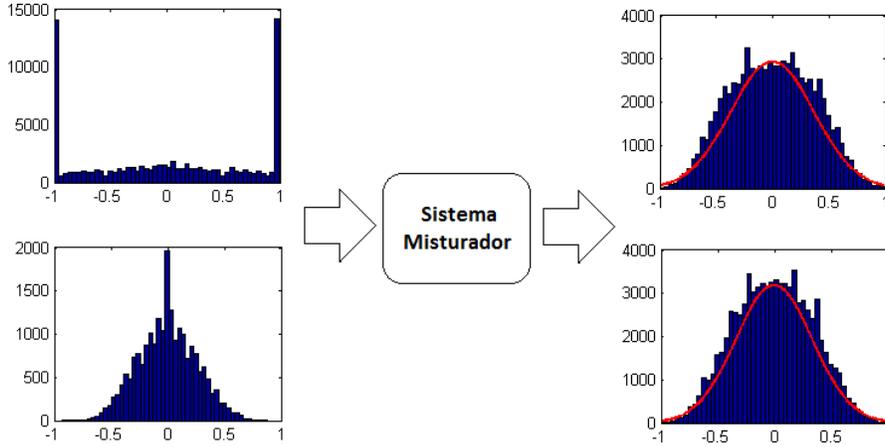


Figura 3.5: A soma ou mistura linear de variáveis aleatórias independentes tende a uma variável com distribuição gaussiana

quarta ordem. Assim é necessário um número elevado de amostras do sinal para que sua estimativa seja confiável. Outro critério utiliza a o conceito de **negentropia**.

A **negentropia** é uma medida normalizada de entropia, ou uma medida da incerteza do valor que uma variável aleatória pode assumir.

$$J_{neg}(x) = H(x_g) - H(x) \quad (3.7)$$

Onde  $x_g$  é uma variável aleatória gaussiana de mesma variância de  $x$ .

A entropia é definida matematicamente como o valor esperado do logaritmo das probabilidades de um evento. É importante perceber que a entropia não depende do valor da variável, mas apenas de sua probabilidade.

$$H(x) = -E \log p_x = - \int p_x(\eta) \log p_x(\eta) d\eta \quad (3.8)$$

Das distribuições que possuem domínio infinito, a gaussiana é a de maior entropia entre as variáveis aleatórias de mesma variância. A entropia também poderia ser utilizada como critério para medir quão gaussiana é uma variável, quanto menor a entropia mais concentrada a variável está ao redor de um certo valor, e menos gaussiana ela é. A entropia diferencial ou negentropia, além de invariante a tranformações lineares inversíveis, é sempre não-negativa. Por tanto, quanto maior a diferença entre a entropia da variável gaussiana e a entropia da variável em questão, esta estará mais distante de ser considerada gaussiana. Deve-se assim maximizar a negentropia para maximizar a não-gaussianidade do sinal da fonte.

A maximização da negentropia é um método robusto, já que é bem explicada pela teoria estatística. Porém, na prática, exige um grande esforço computacional. Aproximações simples desta medida são muito úteis e podem ser utilizadas na implementação de um algoritmo para ICA. Uma aproximação empregada foi utilizando momentos polinomiais:

$$J(y) = \alpha(E\{G(y)\} - E\{G(\nu)\})^2 \quad (3.9)$$

Onde  $G(\cdot)$  é uma função não-linear, não quadrática,  $\alpha$  é uma constante e  $\nu$  é uma variável aleatória com distribuição gaussiana, média nula e variância unitária.

O ponto principal na utilização dessa aproximação é saber escolher, em particular escolhendo funções que não crescem muito rápido, obtendo uma estimação mais robusta. As equações abaixo se mostraram muito úteis:

$$G_1(y) = \frac{1}{a} \log \cosh ay, \text{ para } 1 < a < 2$$

$$G_2(y) = -e^{(-y^2/2)}$$

No algoritmo *FastICA* sugerido por A. Hyvärinen, J. Karhunen e E. Oja em [4] é possível encontrar uma matriz de separação  $W$  única, tal que a projeção  $W^T X$  maximize a não-gaussianidade. O sistema separador deve então ser adaptado de forma a maximizar a negentropia de cada saída  $y_i = w_i x$ :

$$w_{otimoi} = \max_{w_i} (E\{G(w_i x)\} - E\{G(\nu)\})^2 \quad (3.10)$$

Utilizando o método de Lagrange para maximizar a função e considerando que  $x$  foi branquado, obtem-se que:

$$w_i \leftarrow E\{xG'(w_i^T x) - G''(w_i^T x)\}w_i \quad (3.11)$$

O esquema da *fastICA* é baseado no método do ponto fixo para a convergência da matriz  $W^T$ , como veremos no algoritmo a seguir.

Por fim, deve-se garantir a ortogonalização simétrica da matriz  $W$ , através da equação abaixo, ao final de cada iteração. Isto para impedir que o erro na recuperação de uma certa fonte seja propagado para as próximas.

$$W \leftarrow (WW^T)^{-1/2}W \quad (3.12)$$

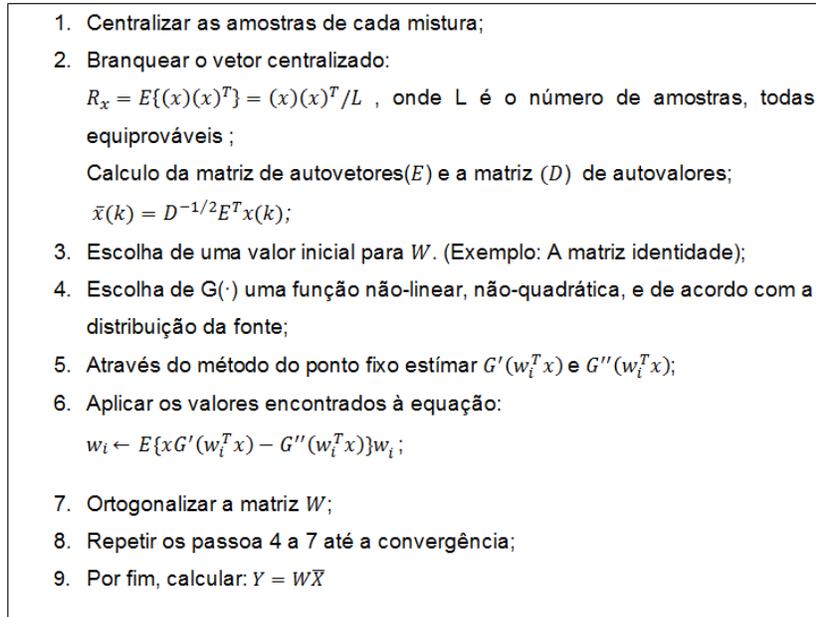


Figura 3.6: Algoritmo fastICA

## 3.4 Algoritmo

Com as amostras provenientes de uma mistura linear, o algoritmo básico proposto para implementação do *fastICA* é resumido no quadro da Figura 3.6. A denominação *fast* se dá devido a rápida convergência do método, que ocorre para a maioria dos casos em apenas 4 ou 5 iterações.

## 3.5 Resultados Iniciais

A fim de testar a eficiência do algoritmo apresentado, misturou-se os sinais branqueados no Exemplo 1. Com a utilização dos sinais senoidais é possível observar a indeterminação da amplitude dos sinais recuperados, além da permutação de fontes, devido a matriz  $Q$ . Os resultados são mostrados na figura 3.7.

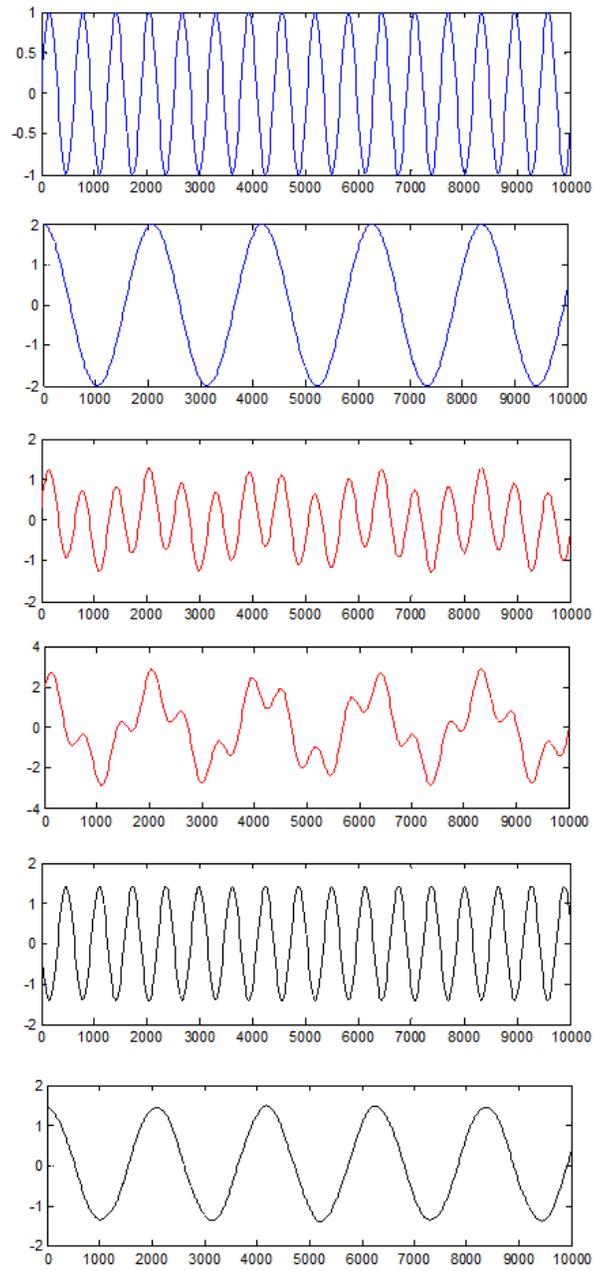


Figura 3.7: De cima para baixo: Os dois sinais originais(azul), seguidos pelos dois sinais misturados(vermelho), e por fim, os dois sinais separados(preto)

# Capítulo 4

## Simulações

### 4.1 Separação de Áudio

Para demonstrar a eficiência do algoritmo apresentado, testes foram feitos na separação de sinais de áudio através de um código implementado no *software* MatLab. Dois sinais com distribuições estatísticas distintas foram escolhidos. Primeiramente foi analisada a distribuição de cada sinal através dos seus respectivos histogramas, de modo a confirmar que não se tratava de uma distribuição gaussiana. Os sinais utilizados foram o áudio de uma ambiente onde tocava uma música, que com distribuição praticamente plana, e o som de uma sirene com uma distribuição mais próxima à gaussiana. Os sinais foram misturados artificialmente, em seguida separados, como mostram a Figura 4.2. Neste caso, a inversão de fase, que pode ser observada na maioria dos sinais separados em relação aos sinais originais da fonte, não acarreta problema algum, já que o ouvido humano não é sensível à fase de qualquer sinal.

### 4.2 Separação de Imagens

Considerando uma imagem como um vetor contendo os valores referentes aos *pixels*, é possível aplicar o algoritmo para separação de duas imagens. A Figura 4.5 mostra as imagens em tons de cinza, que pode ser considerada como um vetor com valores entre 0 e 255 distribuídos aleatoriamente. São apresentadas as imagens misturadas e em seguida separadas utilizando o *fastICA*. Ainda é possível observar na figura do canto inferior direito a inversão nos tons da imagem devido à indeterminação relacionada a matriz de inversão  $W$ . Além de resíduos da outra componente independente na figura do canto inferior esquerdo, devido a sua dis-

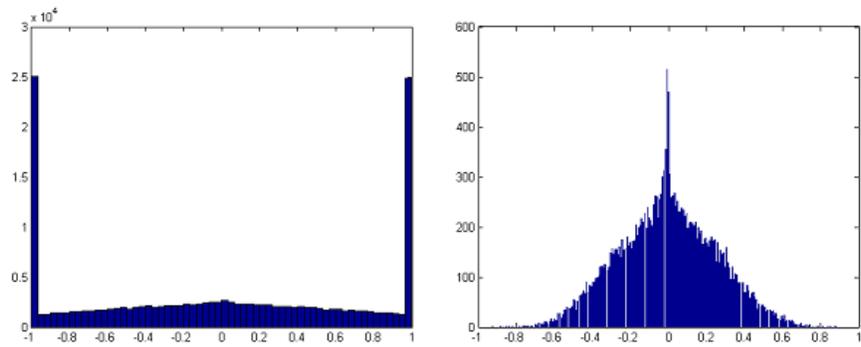


Figura 4.1: Histograma das amostras do sinal de áudio captado em um ambiente(esquerda) e de uma sirene(direita)

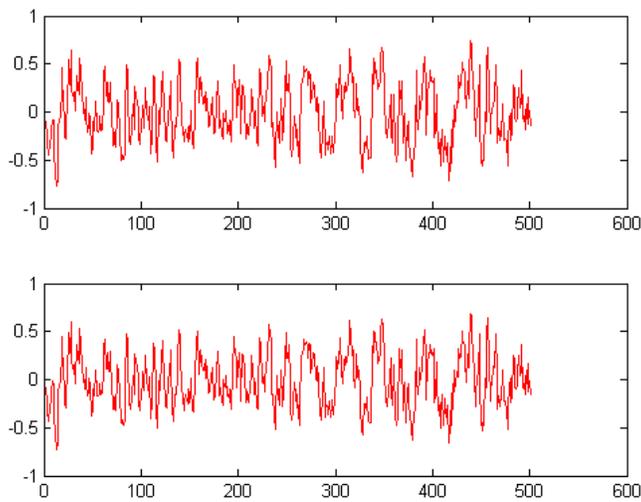


Figura 4.2: Sinais de áudio misturados

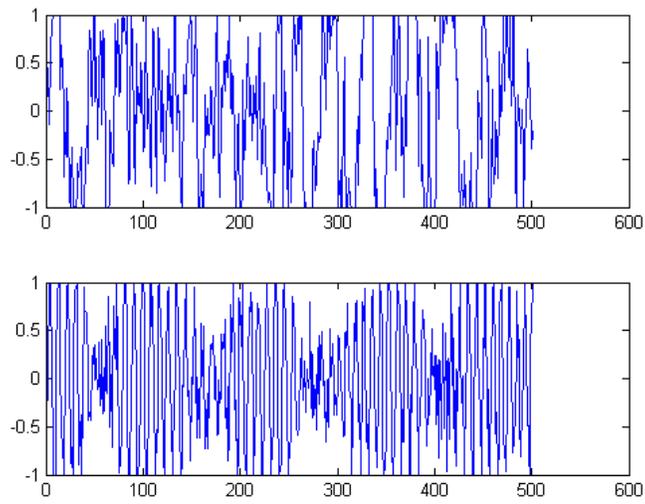


Figura 4.3: Componentes independentes separadss



Figura 4.4: Imagens originais, antes da mistura

tribuição pouco uniforme.

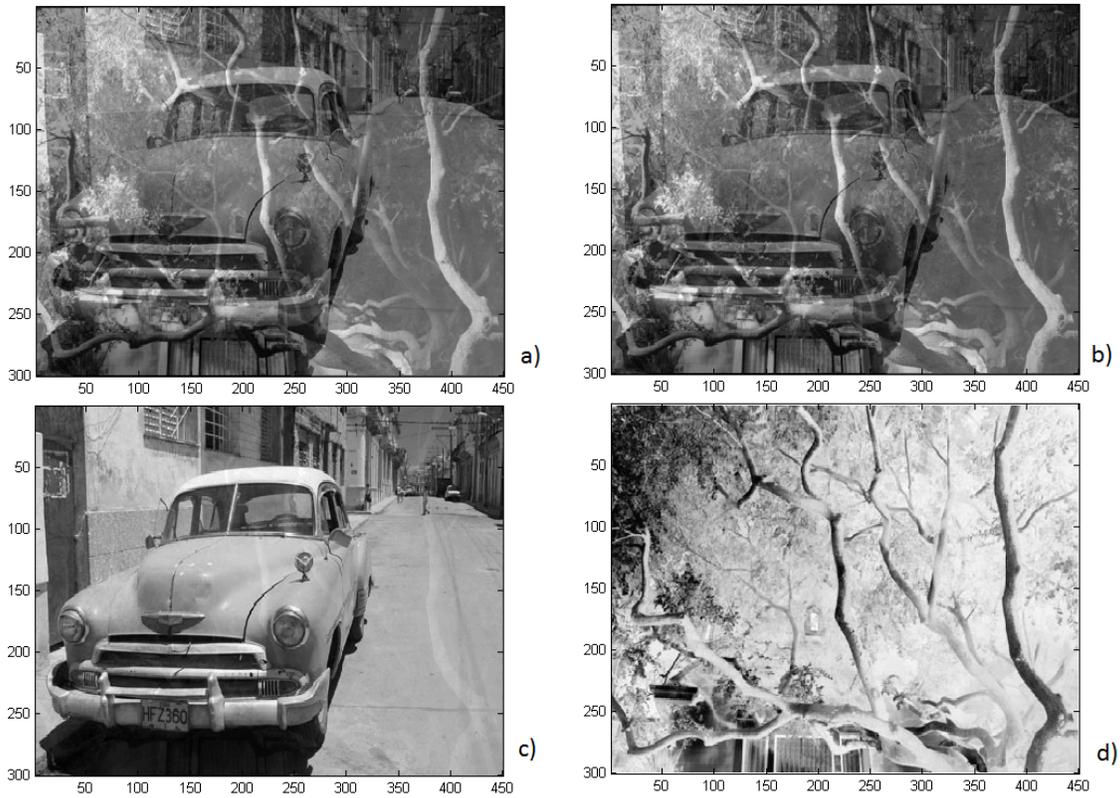


Figura 4.5: Imagens misturadas linearmente a) e b) e separadas c) e d) através de análise de componentes independentes

# Capítulo 5

## Conclusão

A convergência cúbica do algoritmo proposto se destaca diante das demais técnicas para separação de componentes independentes, que possuem convergência linear, na maioria dos casos. Isto implica em uma convergência mais rápida quando se utiliza *fastICA*. Consequentemente, o esforço computacional é menor, assim como a necessidade de memória para armazenamento dos dados.

O método proposto separa de forma direta as componentes independentes de praticamente qualquer distribuição não-gaussiana, para uma dada função custo  $G(\cdot)$ , que quando devidamente escolhida pode otimizar a determinação dos sinais das fontes independentes.

A separação se dá em duas etapas. A primeira, chamada braqueamento, se encarrega de descorrelacionar as amostras dos sinais observados, que é o primeiro passo para a independência entre os sinais das fontes. O segundo consiste em encontrar a matriz de inversão  $W$ , através do método do ponto fixo, em seguida impondo a restrição de ortogonalidade.

O algoritmo implementado utilizando o software MatLab, mostrou-se eficiente e de rápida convergência. Com as simulações feitas através de imagens e sinais de áudio misturados, observou-se as restrições quanto à estatística da fonte.

# Apêndice A - fastICA.m

%Fast ICA with symmetric orthogonalization, Hyvärinen tabela 8.3, pag 196

% Este código faz a ICA entre os sinais Entrada1 e Entrada2, obtendo duas componentes  
% independentes Saida1 e Saida2, utilizando o algoritmo FastICA com ortogonalização  
% simétrica. Esse algoritmo é descrito em detalhes no livro "Independent Component  
% analysis" (2001) de Hyvärinen, Karhunen e Oja, em especial na página 196 que mostra  
% os passos do algoritmo do mesmo modo como está separado o código abaixo. Para a  
% melhor estimativa de grandezas estatísticas os dados de entrada são processados  
% em blocos do tamanho do parâmetro de entrada "janela". O desempenho deve ser  
% comprometido se esse parâmetro for muito pequeno.

```
function [Saida1,Saida2] = fastICA(Entrada1,Entrada2,janela)
```

```
L = length(Entrada1);
```

```
% passo 1: Centralização
```

```
x1 = Entrada1 - mean(Entrada1);
```

```
x2 = Entrada2 - mean(Entrada2);
```

```
% passo 2: Braqueamento
```

```
Rx = [0 0 ; 0 0];
```

```
for n = 1:L
```

```
    Rx = Rx + [x1(n) x2(n)]'*[x1(n) x2(n)];
```

```

end

Rx = Rx/L;

[E,D] = eig(Rx);
V = (D^(-1/2))*E';

x1_bra = zeros(1,L);
x2_bra = zeros(1,L);

for n = 1:L
    x1_bra(n) = V(1,:)*[x1(n) x2(n)]';
    x2_bra(n) = V(2,:)*[x1(n) x2(n)]';
end

% Passo 3: Escolha inicial de W

w1 = [1 0]';
w2 = [0 1]';

% Passo 4: Calculo de W

for n = 1:janela:L-janela

    A1 = [0 0]';
    B1 = 0;
    A2 = [0 0]';
    B2 = 0;

% O calculo do FastICA envolve submeter os dados à uma função não-linear
% não-quadrática e à sua derivada. Algumas funções são comuns no FastICA,
% como tanh e x^3, que é a função utilizada nesse exemplo. A escolha
% da função tem alguma ligação com a distribuição das fontes.

for k = 1:janela
    z = [x1_bra(n+k-1) x2_bra(n+k-1)]';

```

```

    A1 = A1 + z*(w1'*z)^3;
    B1 = B1 + 3*(w1'*z)^2;
    A2 = A2 + z*(w2'*z)^3;
    B2 = B2 + 3*(w2'*z)^2;
end

A1 = A1/janela;
B1 = B1/janela;
A2 = A2/janela;
B2 = B2/janela;

% Maximização da negentropia
w1 = A1 - B1*w1;
w2 = A2 - B2*w2;

W = [w1' ; w2'];

% Procedimento de ortogonalização simétrica.
Wort = ((W*W')^(-1/2))*W;

% Atualiza a matriz para a próxima iteração.
w1 = Wort(1,:);
w2 = Wort(2,:);

end

Saida1 = zeros(1,L);
Saida2 = zeros(1,L);

for n = 1:L
    Saida1(n) = Wort(1,:)*[x1_bra(n) x2_bra(n)];
    Saida2(n) = Wort(2,:)*[x1_bra(n) x2_bra(n)];
end

end

```

## Apêndice B - teste\_audio.m

```
% Este programa tem como intuito testar a eficiência do algoritmo fastICA  
% implementado na função fastICA em fastICA.m. Amostras de dois sinais  
% de áudio misturados mistura1 e mistura2 são processados pela função  
% que retorna os sinais separados separado1 e separado2.
```

```
[mistura1,FS1,NBITS1]=wavread('filepath\mist1.wav');  
[mistura2,FS2,NBITS2]=wavread('filepath\mist2.wav');
```

```
L = length(mistura1);  
fim = 30000;
```

```
figure(1), plot(mistura1',mistura2', 'r.');
```

```
[separado1,separado2] = fastICA(mistura1,mistura2,1000);
```

```
figure(2),  
hold on  
subplot(3,2,3); plot(mistura1(1:fim), 'r')  
subplot(3,2,4); plot(mistura2(1:fim), 'r')  
subplot(3,2,5); plot(separado1(1:fim), 'k')  
subplot(3,2,6); plot(separado2(1:fim), 'k')
```

```
wavwrite(separado1,FS1,NBITS1,'filepath sep1.wav');  
wavwrite(separado2,FS2,NBITS2,'filepath sep2.wav');
```

## Apêndice C - teste\_imagem.m

```
% Este programa tem como intuito testar a eficiência do algoritmo fastICA implementado
% na função fastICA em fastICA.m. Amostras de duas imagens I e J são misturados
% linearmente artificialmente. Os sinais misturados são processados através da
% função que retorna os sinais separados: separado1 e separado2.
```

```
L = 450*300;
```

```
I=imread('filepath\img1.jpg');
```

```
I = rgb2gray(I);
```

```
I = double(I);
```

```
J=imread('filepath\img2.jpg');
```

```
J = rgb2gray(J);
```

```
J = double(J);
```

```
A = I(1,:);
```

```
for n=2:300
```

```
    A = [A I(n,:)];
```

```
end
```

```
B = J(1,:);
```

```
for n=2:300
```

```
    B = [B J(n,:)];
```

```
end
```

```
fontes = [A ; B];
```

```
M = rand(2);
```

```

misturas = M*fontes;

[separado1,separado2,W] = fastICA(misturas(1,:),misturas(2,:),1350);

M1 = [misturas(1,1:450)];
for n=1:300-1
    M1 = [M1; misturas(1,450*n+1:450*n+450)];
end
figure(1),
colormap gray
imagesc(M1);

M2 = [misturas(2,1:450)];
for n=1:300-1
    M2 = [M2; misturas(2,450*n+1:450*n+450)];
end
figure(2),
colormap gray
imagesc(M2);

S1 = [separado1(1:450)];
for n=1:300-1
    S1 = [S1; separado1(450*n+1:450*n+450)];
end
figure(3),
colormap gray
imagesc(S1);

S2 = [separado2(1:450)];
for n=1:300-1
    S2 = [S2; separado2(450*n+1:450*n+450)];
end
figure(4),
colormap gray
imagesc(S2);

```

# Referências Bibliográficas

- [1] Behera, S. K. (2009) Fast ICA for Blind Source Separation and its Implementation, Tese de Doutorado, Department of Electronics and Communication Engineering, National Institute of Technology - Índia.
- [2] Comom P.; Jutten C. (2010) Handbook of Blind Source Separation: Independent Component Analysis and Applications, Livro, 1a Edição, Elsevier Ltd.
- [3] Duarte, L. T. (2006) Um Estudo sobre Separação Cega de Fontes e Contribuições ao Caso de Misturas Não-lineares, Dissertação de Mestrado, Faculdade de Engenharia Elétrica e de Computação, UNICAMP - Brasil.
- [4] Hyvärinen A.; Karhunen J.; Oja E. (2001) Independent Component Analysis, Livro, John Wiley and Sons.
- [5] Hyvärinen, A.; Oja, E. (1997). A fast fixed-point algorithm for independent component analysis. *Neural Computation*, 9:1483-1492.
- [6] Hyvärinen , A.; Oja E. (2000) Independent Component Analysis: Algorithms and Applications, Neural Networks Research Centre, Helsinki University of Technology - Finlândia.
- [7] Jutten, C.; Taleb, A. (2000) Source separation: from dusk till dawn. Proc. 2nd Int. Workshop on Independent Component Analysis and Blind Source Separatio (ICA'2000), págs. 15-26, Finlândia.
- [8] Leite V. C. M. N. (2004) Separação Cega de Sinais: Análise Comparativa entre Algoritmos, Dissertação de Mestrado, Universidade Federal de Itajubá - Brasil.

- [9] Masugi, M.; Hirasawa, N.; Kobayashi, R.; Tajima, K.; Yamane, H. (2009) Proposal of A Novel EMI Diagnostic System using Independent Component Analysis, 20th Int. Zurich Symposium on EMC, págs. 417-420, Suíça.
- [10] Rosa E. S. (2010) Separação cega de sinais em sistemas ópticos com multiplexação de polarização, Dissertação de Mestrado, Faculdade de Engenharia Elétrica e de Computação, UNICAMP - Brasil.
- [11] Suyama, R. (2007) Proposta de métodos de separação cega de fontes para misturas convolutivas e não-lineares, Tese de Doutorado, Faculdade de Engenharia Elétrica e de Computação, UNICAMP - Brasil.
- [12] Vigário, R., Jousmäki, V., Hämäläinen, M., Hari, R., and Oja, E. (1998) Independent component analysis for identification of artifacts in magnetoencephalographic recordings. *Advances in Neural Information Processing Systems*, volume 10, págs. 229-235. MIT Press.