

UNIVERSIDADE DE SÃO PAULO  
FFCLRP - DEPARTAMENTO DE FÍSICA E MATEMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA APLICADA À MEDICINA E  
BIOLOGIA

**“Método de análise de componentes dependentes para o processamento, caracterização e extração de componentes de sinais biomédicos”**

Carlos Alberto Estombelo Montesco

Tese apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP, como parte das exigências para a obtenção do título de Doutor em Ciências, Área: Física Aplicada à Medicina e Biologia.

RIBEIRÃO PRETO -SP

2007

**CARLOS ALBERTO ESTOMBELO MONTESCO**

**“Método de análise de componentes dependentes para o processamento, caracterização e extração de componentes de sinais biomédicos”**

Tese apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP, como parte das exigências para a obtenção do título de Doutor em Ciências, Área: Física Aplicada à Medicina e Biologia.

Orientador: Prof. Dr. Antônio Carlos Roque da Silva Filho

Assessor: Prof. Dr. Dráulio Barros de Araújo

RIBEIRÃO PRETO -SP

2007

## FICHA CATALOGRÁFICA

Estombelo-Montesco, Carlos Alberto

Método de análise de componentes dependentes para o processamento, caracterização e extração de componentes de sinais biomédicos. Ribeirão Preto, 2007.

74 p. : il. ; 30cm

Tese de Doutorado, apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP. Área de concentração: Física Aplicada à Medicina e Biologia.

Orientador: Antônio Carlos Roque da Silva Filho.

1. Extração de componentes. 2. MCGf. 3. MGG. 4. fMRI. 5. Processamento de sinais biomédicos.

*Dedico este trabalho a Eliana e Thiago, meus grandes  
amores, por sua compreensão, seu amor, seu carinho, sua  
presença e apoio durante todo este tempo.*

## **AGRADECIMENTOS**

Ao Prof. Antônio Carlos Roque pela oportunidade, a qual contribuiu no meu crescimento científico e intelectual e, por acreditar no meu trabalho junto ao Departamento de Física e Matemática da Faculdade de Filosofia Ciências e Letras de Ribeirão Preto da USP.

Ao Prof. Dráulio Barros de Araújo pela assessoria durante todo este tempo, discussões, atenção e apoio científico durante o desenvolvimento do trabalho.

Ao Prof. Oswaldo Baffa e ao Prof. Eder Rezende Moraes pelas contínuas discussões e contribuições realizadas durante o trabalho com o objetivo de aprimorar este trabalho de pesquisa.

Ao Prof. Allan Kardec Barros, da Universidade Federal do Maranhão, por sua disposição em colaborar com o trabalho e mostrar sua experiência científica.

A Eliana e Thiago, minhas maiores alegrias, pelo apoio, amor e compreensão.

Na distância aos meus pais Andrés, Eufemia e meu irmão Richard. A Eduardo, Renata, aos meus sogros Albino e Isabel por ter-me apoiado e acreditado na realização deste objetivo.

A todos os amigos do Departamento de Física e Matemática que proporcionaram momentos agradáveis e produtivos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de Doutorado.

## RESUMO

Na área de processamento de sinais biomédicos a extração de informação, baseada em um conjunto de medidas adquiridas no tempo, é considerada de suma importância. A qualidade desta informação extraída permite avaliar o funcionamento dos diversos órgãos. Objetivos: (1) propor o método de análise de componentes dependentes para auxiliar a extração de componentes de interesse, a partir de medidas multivariadas; (2) caracterizar as componentes extraídas através de representações em termos de tempo e frequência, e espectro de potência; e, (3) aplicar o método e avaliar as componentes de interesse extraídas no contexto real MCGf, MGG e fMRI. A proposta para a extração fundamenta-se no método chamado de Análise de Componentes Dependentes – ACD. As medidas a serem processadas são multivariadas a partir de sensores distribuídos, espacialmente, no corpo humano dando origem a um conjunto de dados correlacionados no tempo e/ou no espaço. Observa-se que os sinais de interesse raramente são registrados de forma isolada, e sim misturados com outros sinais superpostos, ruído e artefatos fisiológicos ou ambientais, onde a relação sinal-ruído é geralmente baixa. Nesse contexto, a estratégia a ser utilizada baseia-se na ACD, que permitirá extrair um pequeno número de fontes, de potencial interesse, com informações úteis. A estratégia ACD para extração de informação é aplicada em três importantes problemas, na área de processamento de sinais biomédicos: (1) detecção do sinal do feto em magnetocardiografia fetal (MCGf); (2) detecção da atividade de resposta elétrica do estômago em magnetogastrografia (MGG); e, (3) detecção de regiões ativas do cérebro em experimentos de imagens por ressonância magnética funcional (*Functional Magnetic Resonance Imaging*, fMRI). Os resultados, nos três casos estudados, mostraram que o método utilizado, como estratégia, é efetivo e computacionalmente eficiente para extração de sinais de interesse. Concluímos, baseados nas aplicações, que o método proposto é eficaz, mostrando seu potencial para futuras pesquisas clínicas.

## ABSTRACT

An important goal in biomedical signal processing is the extraction of information based on a set of physiological measurements made along time. Generally, biomedical signals are electromagnetic measurements. Those measurements (usually made with multichannel equipment) are registered using spatially distributed sensors around some areas of the human body, originating a set of time and/or space correlated data. The signals of interest are rarely registered alone, being usually observed as a mixture of other spurious, noisy signals (sometimes superimposed) and environmental or physiological artifacts. More over, the signal-to-noise ratio is generally low. In many applications, a big number of sensors are available, but just a few sources are of interest and the remainder can be considered noise. For such kind of applications, it is necessary to develop trustful, robust and effective learning algorithms that allow the extraction of only a few sources potentially of interest and that hold useful information. The strategy used here for extraction of sources is applied in three important problems in biomedical signal processing: (1) detection of the fetal magnetocardiogram signal (fMCG); (2) detection of the electrical activity of the stomach in magnetogastrograms (MGG); and (3) detection of active regions of the brain in experiments in functional Magnetic Resonance Imaging (fMRI). The results, within the three cases of study, showed that the DCA method used as strategy is effective and computationally efficient on extraction of desired signals.

# ÍNDICE GERAL

<b>CAPÍTULO 1. INTRODUÇÃO .....</b>	<b>14</b>
1.1. CONTEXTUALIZAÇÃO E MOTIVAÇÃO .....	14
1.2. OBJETIVOS.....	16
1.3. ORGANIZAÇÃO.....	17
<b>CAPÍTULO 2. REFERENCIAL TEÓRICO .....</b>	<b>18</b>
2.1. BIOMAGNETISMO E SINAIS BIOMAGNÉTICOS.....	18
2.2. MAGNETOCARDIOGRAFIA FETAL .....	19
2.3. MAGNETOGASTROGRAFIA.....	20
2.4. IMAGEM FUNCIONAL POR RESSONÂNCIA MAGNÉTICA (fMRI) .....	21
<b>CAPÍTULO 3. ANÁLISE DE COMPONENTES.....</b>	<b>24</b>
3.1. ANÁLISE DE COMPONENTES INDEPENDENTES .....	24
3.1.1. <i>Modelo estatístico e definição</i> .....	24
3.1.2. <i>Ambigüidades do modelo</i> .....	28
3.1.3. <i>Separação cega de fontes</i> .....	29
3.1.4. <i>Limitações da ACI</i> .....	32
3.1.5. <i>Necessidade de pré-processamento</i> .....	32
3.2. ANÁLISE DE COMPONENTES DEPENDENTES .....	35
3.2.1. <i>Separação da fonte pela ACD</i> .....	36
3.2.2. <i>Algoritmo de aprendizagem</i> .....	38
3.2.3. <i>Evitando a Permutação</i> .....	39
3.2.4. <i>Evitando o problema de escalamento</i> .....	39
3.3. MODELO AUTO-REGRESSIVO.....	41
3.3.1. <i>Eleição na ordem do modelo</i> .....	42
3.4. TRANSFORMADA DE WAVELET .....	43
3.4.1. <i>Transformada de Morlet</i> .....	44
<b>CAPÍTULO 4. COMPONENTE FETAL A PARTIR DE MAGNETOCARDIOGRAMAS.....</b>	<b>48</b>
4.1. MATERIAL E MÉTODOS .....	48
4.2. RESULTADOS.....	49
<b>CAPÍTULO 5. COMPONENTES GÁSTRICOS A PARTIR DE MAGNETOGASTROGRAMAS.....</b>	<b>52</b>
5.1. MATERIAL E MÉTODOS.....	52
5.2. RESULTADOS.....	58
<b>CAPÍTULO 6. COMPONENTE AUDITIVO A PARTIR DE DADOS DE fMRI .....</b>	<b>65</b>
6.1. MATERIAL E MÉTODOS .....	65
6.2. RESULTADOS.....	70
<b>CAPÍTULO 7. DISCUSSÃO E CONCLUSÕES .....</b>	<b>72</b>

## LISTA DE FIGURAS

FIGURA 1 : REGISTRO DA ATIVIDADE ELÉTRICA GÁSTRICA “ <i>IN VITRO</i> ” E SUA RELAÇÃO COM A ATIVIDADE CONTRÁTIL DO ESTÓMAGO.(MINTCHEV 2007).....	21
FIGURA 2 : DIAGRAMA DE BLOCOS DA ESTIMAÇÃO DA ACI.....	26
FIGURA 3 : APLICAÇÃO DO SISTEMA DE MISTURA <b>A</b> E VICEVERSA <b>W</b> (FERREIRA 2002).....	27
FIGURA 4 : APLICAÇÃO DA ACI AO PROBLEMA DA SCF. A FIGURA MOSTRA OS SINAIS NO DOMÍNIO TEMPO E AS CONCRETIZAÇÕES CONJUNTAS. NA PARTE SUPERIOR OBSERVA-SE AS DUAS COMPONENTES INDEPENDENTES $s_1$ E $s_2$ ; NO MEIO, AS DUAS OBSERVAÇÕES $x_1$ E $x_2$ , ONDE AS CONCRETIZAÇÕES FORMAM UM PARALELOGRAMO DE ARESTAS, PARALELAS ÀS RETAS DEFINIDAS PELAS COLUNAS DA MATRIZ <b>A</b> ; E, NA PARTE INFERIOR, AS COMPOENNETES ESTIMADAS $\hat{s}_1$ E $\hat{s}_2$ (FERREIRA 2002). .....	31
FIGURA 5 : DIAGRAMA DE BLOCOS DA ACI; DETALHE SOBRE O PRÉ-PROCESSAMENTO.....	35
FIGURA 6 : MODELO PARA O NEURÔNIO QUE INCLUI UMA REFERENCIA INTERNA (OU PADRÃO)(BARROS AND CICHOCKI 2002). .....	36
FIGURA 7 : QUATRO <i>WAVELETS</i> DE MORLET DIFERENTES. AS <i>WAVELETS</i> MOSTRADAS EM A), B) E C) TÊM A MESMA “LARGURA”, $\tilde{W}$ , IGUAL A 7. A LARGURA DA BANDA ESPECTRAL SE AMPLIA QUANDO AS FREQUÊNCIAS SÃO AUMENTADAS. OBSERVADO TAMBÉM QUANDO O ENVELOPE DA <i>WAVELET</i> SE TORNA MAIS AGUDO. POR OUTRO LADO, QUANDO $\tilde{W}$ É DIVIDIDA PELA METADE O NÚMERO DE OSCILAÇÕES DA <i>WAVELET</i> TAMBÉM É DIVIDIDO PELA METADE, COMO OBSERVADO EM D). A LINHA SÓLIDA É A PARTE REAL DA <i>WAVELET</i> COMPLEXA, E A LINHA TRACEJADA É A PARTE IMAGINARIA.....	46
FIGURA 8 : DEZ SEGUNDOS DE DADOS OBSERVADOS, PARA 5 DOS 37 CANAIS DE MCGF REGISTRADOS. OS REGISTROS MOSTRAM OS SINAIS DA MÃE E DO FETO SOBREPOSTOS. ....	49
FIGURA 9 : ESPECTRO DE POTÊNCIA DE UM REGISTRO SIMPLES. DOIS PICOS CORRESPONDENTES À COMPONENTE FETAL E À COMPONENTE DA MÃE SÃO OBSERVADOS. ....	50
FIGURA 10 : COMPONENTES SEPARADAS DO MCG DA MÃE (A) E DO MCG FETAL (B), OBTIDAS POR FASTICA, E MCG FETAL (C) EXTRAÍDO POR ACD BASEADO NA ANÁLISE ESPECTRAL AUTO-REGRESSIVA. ESTA ÚLTIMA É CONSIDERADA UM SINAL MAIS CONSISTENTE COM OS BATIMENTOS CARDIACOS FETAIS. BÁSICAMENTE, A DIFERENÇA ENTRE (B) E (C) É O MÉTODO UTILIZADO, TENDO CADA UM SEU PRÓPRIO FORMA PARA APROXIMAR A COMPONENTE FETAL. ....	51
FIGURA 11 : DIAGRAMA ILUSTRATIVO DO MÉTODO APLICADO. (A) CADA FONTE (ESTÓMAGO, CORAÇÃO, TEÇIDO, ARTEFATOS, ETC) PRODUZ UM SINAL MAGNÉTICO,NÃO OBSERVADO DIRETAMENTE NA PRÁTICA. (B) OS SINAIS DE CADA FONTE SÃO MISTURADOS (LINEARMENTE, POR HIPÓTESE) COM OS SINAIS DAS OUTRAS FONTES E, A MISTURA É REPRESENTADA PELO BLOCO DENOMINADO “PROCESSO DE MISTURA”. (C) OS SINAIS ADQUIRIDOS POR CADA CANAL DO MAGNETÔMETRO SÃO, NA VERDADE, MISTURAS DOS SINAIS ORIGINAIS. (D) APÓS A AQUISIÇÃO DOS SINAIS MISTURADOS FOI REALIZADA A SEPARAÇÃO/EXTRAÇÃO DA FONTE DE INTERESSE ATRAVÉS DO PROCESSO DE ACD. (E) FINALMENTE, NA SAIDA HÁ UMA ÚNICA SÉRIE TEMPORAL DETERMINADA A MENOS DE UM FATOR DE ESCALA, QUE PRECISA SER CALCULADA PARA ESTIMAR SUA AMPLITUDE RELATIVA. ESTES PASSOS FORAM APLICADOS PARA OS TRÊS REGISTROS MEDIDOS, O PRÉ-PRANDIAL E AS DUAS PÓS-PRANDIAIS, RESPECTIVAMENTE. ....	53
FIGURA 12 : O PAINEL SUPERIOR MOSTRA O SINAL ORIGINAL CORRESPONDENTE AO REB OBSERVADO APÓS A DECIMAÇÃO, SEM NENHUM TIPO DE PROCESSAMENTO. O PAINEL INFERIOR MOSTRA O ESPECTRO DE POTÊNCIA DO SINAL DO PAINEL SUPERIOR, INDICANDO CLARAMENTE O SINAL REB EM 0,05 Hz (3 cpm.).....	54
FIGURA 13 : O PAINEL SUPERIOR MOSTRA A SERIE TEMPORAL ORIGINAL DO REGISTRO PRE-PRANDIAL APÓS DECIMAÇÃO E, FILTRAGEM DAS FREQUENCIAS BAIXAS. O PAINEL INFERIOR MOSTRA O ESPECTRO DE POTENCIA DA AER DOS REGISTROS NO PRE-PRANDIAL, MOSTRADOS NO PAINEL ACIMA. O SINAL AER APRESENTA ENERGIA FRACA QUANDO COMPARADO À COMPONENTE DO CORAÇÃO NAS ALTAS FREQUENCIAS.....	55
FIGURA 14 : O PAINEL SUPERIOR MOSTRA O SINAL ORIGINAL DO PRIMEIRO REGISTRO PÓS-PRANDIAL, APÓS DECIMAÇÃO E FILTRAGEM DAS FREQUENCIAS BAIXAS (ABAIXO DE 0.35Hz). O PAINEL INFERIOR MOSTRA O ESPECTRO DE POTÊNCIA DESTA SINAL, COM FORTE PICO, APROXIMADAMENTE DE 1,5 Hz, ASSOCIADO AO RITMO CARDÍACO E, O PICO DA ARE BASTANTE INTENSO QUANDO COMPARADO COM O PRÉ-PRANDIAL, 0,8Hz RESPECTIVAMENTE. ....	56
FIGURA 15 : SINAIS DO REB (LINHA PONTILHADA) E DA ARE (LINHA SÓLIDA) EXTRAÍDOS USANDO A ACD. (A) COMPONENTES EXTRAÍDAS NO REGISTRO PRE-PRANDIAL, (B) E (C) COMPONENTES EXTRAÍDAS PARA O PRIMEIRO E SEGUNDO REGISTRO PÓS-PRANDIAL. DO LADO DIREITO MOSTRA-SE A ESCALA USADA PARA O SINAL DO REB E, DO LADO ESQUERDO, MOSTRA-SE A ESCALA USADA PARA O SINAL DA ARE. O SINAL DO REB É UM <i>UPSTROKE</i> SEGUIDO POR UM PLATÔ E, PELA FASE DE DESPOLARIZAÇÃO LENTA COM UMA FREQUÊNCIA APROXIMADA DE 3 cpm. NOTE A DIFERENCIA DE AMPLITUDE ENTRE O SINAL DO REB NO	

REGISTRO PRÉ-PRANDIAL E O SINAL DA ARE NOS DOIS REGISTROS PÓS-PRANDIAIS. SENDO A ESCALA DO EIXO $x$ EM SEGUNDOS. ....	59
<b>FIGURA 16:</b> CONTRIBUIÇÕES DOS CANAIS PARA O SINAL DO REB EXTRAÍDO COM ACD. (A) MAPA DE CONTORNO DO SINAL DO REB NO REGISTRO PRE-PRANDIAL. (B) MAPA DE CONTORNO DO SINAL DO REB DO REGISTRO PÓS-PRANDIAL. NESSES REGISTROS, A ENERGIA INTENSA, DE ONDA LENTA, SE APRESENTA O TEMPO TODO. .	60
<b>FIGURA 17:</b> CONTRIBUIÇÕES DOS CANAIS PARA O SINAL DA ARE EXTRAÍDA COM ACD. (A) MAPA DE CONTORNO PARA O SINAL DA ARE NO REGISTRO PRE-PRANDIAL. NESSE REGISTRO É ESPERADO QUE A ARE NÃO APRESENTE CONTRIBUIÇÃO, CONSIDERANDO QUE NO REGISTRO PRE-PRANDIAL NÃO HÁ CONTRAÇÕES. (B) MAPA DE CONTORNO PARA O SINAL DA ARE NO PRIMEIRO REGISTRO PÓS-PRANDIAL, MOSTRANDO CLARAMENTE UMA MUDANÇA NO PADRÃO ESPACIAL.....	60
<b>FIGURA 18:</b> INTERVALO DE TEMPO DURANTE O REGISTRO PRÉ-PRANDIAL, COM AS COMPONENTES DO REB E DA ARE NO PAINEL SUPERIOR E, A RTF DA COMPONENTE DA ARE NO PAINEL INFERIOR. A LINHA BRANCA CONTÍNUA SOBREPOSTA À RTF DO PAINEL INFERIOR É A SOMA DAS COMPONENTES DO REB E DA ARE. A ESCALA DO LADO ESQUERDO CORRESPONDE À COMPONENTE DA ARE E, A ESCALA DO LADO DIREITO CORRESPONDE À COMPONENTE DO REB. ....	61
<b>FIGURA 19:</b> INTERVALO DE TEMPO DURANTE O PRIMEIRO REGISTRO PÓS-PRANDIAL MOSTRANDO AS COMPONENTES DO REB E DA ARE. PODE-SE OBSERVAR OS POTENCIAIS DE AÇÃO ASSOCIADOS À COMPONENTE DA ARE NO PAINEL SUPERIOR, CORRESPONDENTES COM OS PONTOS LUMINOSOS NA RTF DO PAINEL INFERIOR, EM FASE COM A COMPONENTE DO REB. A FREQUÊNCIA DA COMPONENTE DA ARE NA RTF VARIA DE 0,6 Hz. A 1,0 Hz. AS ESCALAS DESTA FIGURA SÃO SIMILARES ÀS DA FIGURA ANTERIOR. ....	62
<b>FIGURA 20:</b> INTERVALO DE TEMPO DURANTE O SEGUNDO REGISTRO PÓS-PRANDIAL MOSTRANDO AS COMPONENTES DO REB E DA ARE. NOTE-SE QUE O SINAL DA ARE ESTÁ MAIS DISTRIBUIDO, QUANTO O TEMPO E A FREQUÊNCIA, EMBORA MANTENHA-SE EM FASE COM A COMPONENTE DO REB. ....	63
<b>FIGURA 21:</b> ESPECTRO DE POTÊNCIA AUTO-REGRESSIVO DA COMPONENTE DA ARE DURANTE O REGISTRO PRÉ-PRANDIAL E, OS DOIS REGISTROS PÓS-PRANDIAIS DE UM SUJEITO, APÓS SUA EXTRAÇÃO PELO MÉTODO DA ACD. A INSERÇÃO MOSTRA O ÍNDICE CALCULADO PARA CADA REGISTRO. ....	64
<b>FIGURA 22:</b> ESQUEMA DO PROTOCOLO EM BLOCOS USADO DURANTE O EXPERIMENTO. OS 64 PONTOS DO EIXO HORIZONTAL SÃO EQUIVALENTES A 289,8 SEGUNDOS. OS PRIMEIROS 12,7 S FORAM UTILIZADOS PARA CALIBRAÇÃO DO APARELHO. ....	66
<b>FIGURA 23 :</b> EXEMPLO DE MEDIDA DE fMRI SEM PROCESSAMENTO DE EXTRAÇÃO. MATRIZ ORIGINAL DE 128x128 PIXELS, FATIA 12, AMOSTRAGEM 32 DE 64 PONTOS. ....	67
<b>FIGURA 24 :</b> MODELO DA FUNÇÃO HEMODINÂMICA UTILIZADA NOS DADOS SIMULADOS. ....	68
<b>FIGURA 25 :</b> SÉRIE TEMPORAL DE FUNÇÕES DE RESPOSTA HEMODINAMICAS BASEADAS NO MODELO DA FIGURA 24 : .....	68
<b>FIGURA 26 :</b> ESPECTRO DE POTÊNCIA AR DE UMA SÉRIE TEMPORAL PERTENCENTE A UM VOXEL. OBSERVA-SE A EXISTENCIA DA COMPONENTE EM TORNO DE 0,018 Hz.....	70
<b>FIGURA 27 :</b> COMPONENTE AUDITIVA EXTRAÍDA. PARA UM SINAL QUASE-PERIODICO, A ACD IDENTIFICA A COMPONENTE BASEADA NO ATRASO TEMPORAL DETERMINADO A PARTIR DAS CARATERÍSTICAS TEMPORAIS DA RESPOSTA HEMODINÂMICA AUDITIVA. ....	71
<b>FIGURA 28 :</b> ÁREA DE ATIVIDADE DETECTADA NO EXPERIMENTO DE fMRI AUDITIVO (FATIA 12 DO TOTAL DE 16 FATIAS). MAPA DE LOCALIZAÇÃO DA ATIVIDADE OBTIDO POR CORRELAÇÃO CRUZADA ENTRE A COMPONENTE EXTRAÍDA (REPRESENTANDO A FUNÇÃO DE RESPOSTA HEMODINÂMICA AUDITIVA) E O CONJUNTO DE DADOS ORIGINAIS (OBSERVAÇÕES), OBTIDOS POR fMRI.....	71

## LISTA DE TABELAS

TABELA 1: EFEITO DA "LARGURA", $\tilde{W}$ , DA <i>WAVELET</i> DE MORLET NO SEU DESEMPENHO EM DIFERENTES FREQUÊNCIAS $f_0$ . $2\sigma_t$ É A DURAÇÃO DA <i>WAVELET</i> E, $2\sigma_f$ É A LARGURA DA BANDA ESPECTRAL DA <i>WAVELET</i> NA FREQUÊNCIA EXISTENTE NA TABELA. DESSA FORMA, ESSES VALORES DETERMINAM O ÓTIMO DESEMPENHO DA <i>WAVELET</i> .....	47
TABELA 2: NO CASO DO REB (3 CPM), A TABELA MOSTRA O EFEITO DE $\tilde{W}$ NA <i>WAVELET</i> DE MORLET PARA DIFERENTES FREQUÊNCIAS $f_0$ . NESTE ESTUDO, O PARÂMETRO FOI CONFIGURADO UTILIZANDO O VALOR DE $\tilde{W} = 3,5$ .....	57
TABELA 3 : NO CASO DA ARE, A TABELA MOSTRA VÁRIAS CONFIGURAÇÕES DE VALORES DE $\tilde{W}$ E $f_0$ PARA A <i>WAVELET</i> DE MORLET. SENDO O PARÂMETRO CONFIGURADO UTILIZANDO O VALOR DE $\tilde{W} = 21$ . ....	58
TABELA 4 : ÍNDICE PARA CADA REGISTRO (ENTRE 0,5 Hz E 1,33 Hz) $\times 10^{51}$ .....	64

## LISTA DE SIGLAS

ACI	Análise de Componentes Independentes
ACD	Análise de Componentes Dependentes
AR	Auto-regressivo
AIC	Critério de Informação de Akaike
ARE	Atividade de resposta Elétrica
BOLD	<i>Blood Oxygen level dependent</i>
BSS	<i>Blind Source Separation</i>
DCA	<i>Dependent Component Analysis</i>
DNOS	contraste "dependente no nível de oxigênio no sangue"
ECGf	Eletrocardiografia fetal
EKG	Eletrogastrografia
EQM	Erro quadrático Médio
EPI	echo-planar imaging ou imagem eco-planar
fMRI	functional Magnetic Resonance Imaging ou Image funcional por ressonância magnética
fdp	Função de densidade de probabilidade
FFT	Trasnformada rápida de Fourier
FRH	Função de resposta Hemodinâmica
ICA	<i>Independent Component Analysis</i>
MCGf	Magnetocardiografia fetal
MGG	Magnetogastrografia
MCG	Magnetocardiografia
RTF	Representação tempo-frequência
REB	Ritmo Elétrico de Base

SQUID	Superconductor de interferência quântica
SCF	Separação cega de fontes

## CAPÍTULO 1. INTRODUÇÃO

### 1.1. CONTEXTUALIZAÇÃO E MOTIVAÇÃO

Um objetivo importante na área de processamento de sinais biomédicos é a extração de informação baseada em um conjunto de medidas feitas ao longo do tempo (**James and Hesse 2005**). Em grande parte dos casos, sinais biomédicos são medidas eletromagnéticas, embora outras quantidades físicas ou químicas também, possam ser avaliadas. Essas medidas, geralmente realizadas utilizando aparelhos multicanais, são registradas usando sensores distribuídos espacialmente no corpo humano, dando origem a um conjunto de dados correlacionados no tempo e/ou no espaço.

Com relação ao sinal adquirido, deve-se conhecer que a informação, inerente às medidas, depende geralmente do domínio de aplicação, sendo necessário considerar as posições e o número de sensores. Os sinais de interesse raramente são registrados de forma isolada, mas observados misturados com sinais espúrios, ruídos e artefatos fisiológicos ou ambientais, em consequência, a relação sinal-ruído é geralmente baixa. As vezes, ainda, os dados, contêm medidas superpostas, as que são geradas por fontes localizadas em diferentes partes do corpo humano.

Assim, ruído para uma imagem ou um sinal é, de forma geral, qualquer variação que represente o desvio a partir do verdadeiro sinal ou imagem (**Kaufman et al. 1989**). A fonte dos ruídos pode ser de origem sistêmico ou aleatório, este último pode ser denominado não repetitivo e, pode ter algum tipo de distribuição estatística. A estrutura deste ruído e sua caracterização é considerada, neste estudo, como todo o que modifica o sinal, ou seja a fonte original, sendo indesejável durante a avaliação da componente.

Por outro lado, médicos e/ou especialistas procuram nos sinais biomédicos, prévio treinamento e experiência, diferentes padrões de atividade com alguma distribuição espacial em particular. Assim, tentam descobrir e/ou desfazer a mistura visualmente observada. Portanto, é de interesse para o diagnóstico de doenças, se através da automatização e análise de sinais biomédicos, fosse possível conseguir:

Reverter a mistura e isolar um conjunto de sinais biomédicos em suas componentes constituintes, chamadas também de fontes;

- Fornecer a informação sobre o número de fontes distintas que estão sendo observadas;
- Fornecer uma distribuição espacial de acordo com a série temporal pertencente à fonte;
- Rastrear as mudanças no número de fontes identificadas, suas distribuições espaciais e sua morfologia, ao longo do tempo.

Nesse sentido, a separação cega de fontes (*Blind Source Separation*, BSS) pode ser utilizada para a análise de componentes independentes (*Independent Component Analysis*, ICA), sendo uma ferramenta que oferece soluções perante os problemas citados. A ICA é uma técnica que, essencialmente, extrai um conjunto de fontes subjacentes ou componentes independentes a partir de um conjunto de variáveis aleatórias, medidas ou sinais. Esta técnica, basicamente, utiliza conjuntos de dados multivariados para definir um modelo, baseado em dados observados. Essa técnica considera que as componentes são desconhecidas, misturadas linearmente, tentando reverter o processo de mistura através da separação de fontes e da exploração da independência estatística.

Assim, encontram-se disponíveis um quantitativo de sensores para inúmeras aplicações, porém, na prática um número limitado de fontes são de interesse, sendo o restante considerado como ruído. Para esse tipo de aplicações é necessário desenvolver algoritmos de aprendizagem confiáveis, robustos e efetivos, que permitam extrair apenas uma pequena

quantidade de fontes, que sejam de potencial interesse, e que ofereçam informações úteis **(Barros et al. 2000)**.

Barros e Cichoki (2001) propuseram um algoritmo alternativo à ICA, no qual é possível separar as sinais de interesse, sendo um método que utiliza informação *a priori*, ligada a componentes de frequência.

## 1.2. OBJETIVOS

Neste estudo, o método proposto por Barros e Cichoki foi adaptado, recebendo o nome de análise de componentes dependentes (Dependent Component Analysis, DCA), e aplicado para separação de fontes em três importantes problemas, na área de processamento de sinais biomédicos: (1) detecção do sinal do feto em magnetocardiografia fetal (MCGf) **(de Araujo et al. 2005)**; (2) detecção da atividade de resposta elétrica do estômago em magnetogastrografia (MGG) **(Estombelo-Montesco et al. 2007a)**; e, (3) detecção de regiões ativas do cérebro em experimentos de imagens por ressonância magnética funcional (*Functional Magnetic Resonance Imaging*, fMRI) **(Estombelo-Montesco et al. 2007b)**.

Sendo assim, os objetivos deste trabalho são:

- Propor o método de análise de componentes dependentes para auxiliar a extração de componentes de interesse, a partir de medidas multivariadas;
- Caracterizar as componentes extraídas através de representações em termos de tempo e frequência, e espectro de potência;
- Aplicar o método e avaliar as componentes de interesse extraídas no contexto real da MCGf;
- Aplicar o método e avaliar as componentes de interesse extraídas no contexto real da MGG;
- Aplicar o método e avaliar as componentes de interesse extraídas no contexto real de fMRI.

### 1.3. ORGANIZAÇÃO

O trabalho foi estruturado de forma a apresentar o contexto teórico no qual está inserido, bem como, os resultados obtidos e suas contribuições para a comunidade acadêmica.

No **Capítulo 2** é mostrado um referencial teórico de biomagnetismo e sinais biomagnéticos, sendo brevemente descritas a magnetocardiografia fetal, a magnetogastrografia e a imagem funcional por ressonância magnética.

O **Capítulo 3** apresenta conceitos de análise de componentes independentes, análise de componentes dependentes, método estratégico para este estudo, e outros métodos que auxiliaram na caracterização e, processamento dos sinais, tais como o modelo autoregressivo e a representação tempo-frequência.

O **Capítulo 4** mostra uma aplicação do método proposto na área de magnetocardiograma fetal. A aplicação concentra-se na extração da componente fetal, considerando a componente materna e o ruído existente no ambiente, ou outros artefatos originados por outros órgãos.

No **Capítulo 5** é mostrada uma segunda aplicação na área de magnetogastrografia. Na qual, a presença de componentes originadas através da mistura de componentes, uma de baixa e outra de alta frequência, têm características comuns quando medida a atividade elétrica no pré e pós-prandial.

O **Capítulo 6** mostra uma aplicação na área de imagens por ressonância magnética funcional. Assim, observa-se que quando executada uma tarefa auditiva são ativadas e localização determinadas áreas do cérebro.

Finalmente, o **Capítulo 7 apresenta as** conclusões do presente estudo.

## CAPÍTULO 2. REFERENCIAL TEÓRICO

### 2.1. BIOMAGNETISMO E SINAIS BIOMAGNÉTICOS

Biomagnetismo é uma área de pesquisa que procura medir e analisar os campos magnéticos gerados por órgãos humanos (**Carneiro et al. 2000**). De maneira geral, a finalidade é buscar um maior entendimento sobre os processos fisiológicos dos diversos órgãos, além de desenvolver e aprimorar técnicas de diagnóstico não-invasivas e eficientes.

Os campos magnéticos produzidos pelos humanos são muito fracos, sendo sua potencia de  $10^{-9}$  até  $10^{-14}$  T, quando comparado com o campo magnético da Terra, de  $10^{-4}$  T respectivamente. (**Carneiro et al. 2000**).

O corpo humano produz campos magnéticos associados a correntes elétricas iônicas, geradas pela atividade de despolarização das células, através de partículas ferromagnéticas ou paramagnéticas localizadas nos órgãos. Substâncias magnéticas são marcadores, que quando ingeridos ou injetados no organismo produzem campos magnéticos, além de outras funções. Baseados na medição desses campos é possível localizar com precisão uma determinada região e, determinar as características das fontes associadas, isto é, a intensidade da corrente ou a concentração de partículas, paramagnéticas ou ferromagnéticas (**Carneiro et al. 2000**).

Assim, campos de maior intensidade, gerados pelo organismo podem ser medidos por um dispositivo chamado de magnetômetro de fluxo saturado, ou *fluxgate*. No entanto, a maioria dos campos, por serem de pouca intensidade, são medidos através de um dispositivo criogênico, de grande sensibilidade, denominado superconductor de interferência quântica, ou com a sigla SQUID (**Carneiro et al. 2000**).

## 2.2. MAGNETOCARDIOGRAFÍA FETAL

Dentre as diversas aplicações do biomagnetismo, a magnetocardiografia (MCG) – medida restrita a campos magnéticos gerados pelo coração – é uma das mais ressaltantes em virtude da grande incidência de doenças cardiovasculares na população (**Comani et al. 2004**). Os sinais do coração, tipo picoteslas, são medidos por sensores SQUID posicionados sobre a pele, que fornecem informação das fontes de atividade elétrica cardíaca sem necessidade de fixação de eletrodos no paciente, diferente das medidas eletrofisiológicas convencionais realizadas (**Carneiro et al. 2000**).

A magnetocardiografia fetal (MCGf) é a sub-área da MCG voltada para a medida de campos magnéticos gerados pelo coração do feto. Neste caso, os sensores SQUID são posicionados sobre o abdômen da mãe. A MCGf apresenta grandes vantagens quando comparada com a eletrocardiografia fetal (ECGf). Nesta última, os sinais obtidos por eletrodos sofrem muita interferência pelo coração da mãe, como consequência de sinais elétricos com baixa relação sinal/ruído; e, pela presença da *vernix caseosa* na pele do feto, a partir da vigésima quinta semana de gestação, sendo esta considerada uma substância de baixa condutividade e que atua como isolante elétrico (**de Araujo et al. 2005**).

O coração do feto produz campos magnéticos mais francos, quando comparados com os da mãe. Ainda, apresenta interferências tais como o sinal cardíaco e a respiração da mãe e, inclusive o próprio movimento fetal. Outra dificuldade observada é o pequeno volume do coração e a distância com relação aos sensores, considerando que estes sinais magnéticos fetais exigem uma ótima relação sinal-ruído. Desta forma, a MCGf apresenta uma boa relação sinal-ruído durante todo o período de gestação e permite uma ótima definição na forma de onda, sendo uma excelente técnica para acompanhar a atividade cardíaca fetal (**Baffa et al. 1995**).

Da mesma forma, a MCGf pode ser usada a partir da décima quinta semana de gestação, muito antes da ECGf (**de Araujo et al. 2005**), o que permite a detecção precoce de anomalias congênitas tornando possível realizar uma intervenção antes do parto (**Carneiro et al. 2000**).

### **2.3. MAGNETOGASTROGRAFÍA**

As contrações dos músculos da parede do estômago durante a digestão, assim como no coração, produzem campos elétricos factíveis de ser medidos, utilizando para tal finalidade eletrodos posicionados sobre a pele, técnica denominada de eletrogastrografia (EGG). Assim a atividade elétrica estomacal é medida por sensores SQUID, utilizando a técnica conhecida como magnetogastrografia (MGG) (**Carneiro et al. 2000**).

A MGG permite a obtenção de maior quantidade de informação sobre a atividade elétrica do estômago quando comparada com o EGG. Os sinais magnéticos são menos afetados pela condutividade elétrica do tecido, dependendo prioritariamente da distância entre a fonte e o detector, que dos próprios sinais elétricos (**Andrä and Nowak 2006**), o que oferece uma melhor resolução espacial e maiores vantagens que a EGG (**Carneiro et al. 2000**).

A atividade elétrica gástrica (Figura 1) constituída por duas componentes: ritmo elétrico de base, não necessariamente associado aos movimentos de contração estomacal, observada como onda elétrica lenta (com frequência de três ciclos por minuto em humanos); e, uma atividade de resposta elétrica, que ocorre em conjunção com os movimentos de contração estomacal, que é caracterizada por potenciais de ação durante a fase de platô do ritmo elétrico de base (**Irimia et al. 2006; Mintchev 2007**).

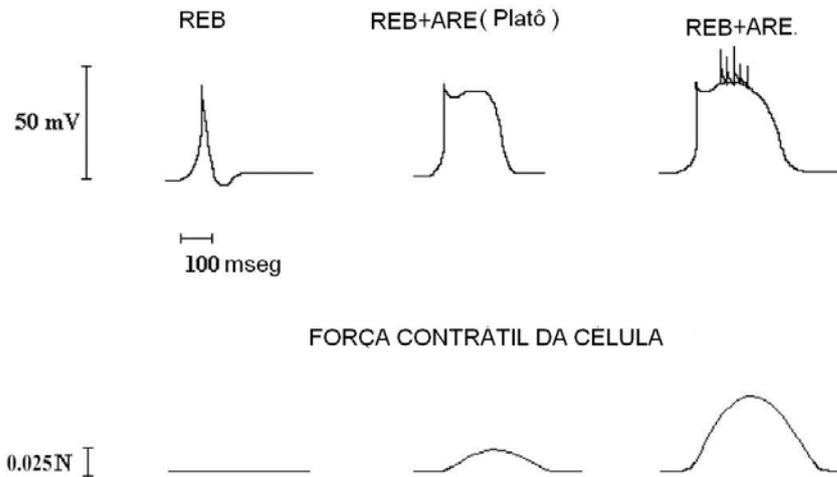


Figura 1 : Registro da atividade elétrica gástrica “*in vitro*” e sua relação com a atividade contrátil do estômago. (Mintchev 2007)

A detecção e a caracterização da atividade de resposta elétrica são consideradas de grande importância em gastroenterologia. Da mesma forma, a MGG tem potencial para oferecer uma importante contribuição nesta área, por ser uma técnica não-invasiva. Porém, os principais problemas para a detecção da atividade de resposta elétrica por meio de MGG decorrem do fato que, o sinal da atividade de resposta elétrica possui amplitude relativamente baixa e está sujeito a interferências de outros sinais corporais, como os cardíacos e respiratórios.

#### 2.4. IMAGEM FUNCIONAL POR RESSONÂNCIA MAGNÉTICA (FMRI)

A área de neuroimagem funcional teve um grande progresso nos últimos anos. Imagens com resolução anatômica milimétrica e resolução temporal da ordem de milisegundos possibilitam, de forma não-invasiva, a caracterização espaço-temporal de uma gama de processos cognitivos, bem como a sua utilização em algumas rotinas clínicas (de Araujo 2002).

O princípio da imagem funcional por ressonância magnética (fMRI)<sup>1</sup> para o mapeamento de regiões cerebrais ativas é relativamente simples. As informações de interesse, desde o ponto de vista clínico, obtidas através da fMRI são, geralmente, alcançadas através de diferença entre imagens que refletem dois estados de atividade cerebral distintos - em atividade e em repouso.

Os neurônios quando ativos consomem oxigênio presente nas moléculas de hemoglobina, no sangue. Assim, quando incrementada a atividade em uma determinada região do cérebro é provocado um aumento do fluxo sanguíneo e do consumo de oxigênio. Reação que provoca alterações posteriores nas concentrações de oxi-hemoglobina e deoxi-hemoglobina (formas oxigenada e a não-oxigenada da molécula de hemoglobina, respectivamente).

Por sua vez, a oxi-hemoglobina é considerada diamagnética e a deoxi-hemoglobina é considerada paramagnética, o que ocasiona diferenças na susceptibilidade magnética. Assim, quando alterada esta susceptibilidade no cérebro, também é alterado o tempo de relaxamento, como resposta característica do tecido frente uma seqüência apropriada de pulsos de rádio-freqüência, o qual altera o contraste das imagens, sendo denominado de efeito BOLD (*blood oxygen level dependent*)<sup>2</sup>. Técnicas para a aquisição rápida de imagens permitem explorar o efeito BOLD e obter uma visualização de diversos padrões na atividade cerebral **(de Araujo 2002)**.

Nos exames de fMRI as alterações nos contrastes das imagens quando tênues, geram imagens repetidas de uma mesma região cerebral. Portanto, é de importância a aquisição rápida de imagens, que reduza o tempo de duração e minimizem a possibilidade de movimentos involuntários durante sua execução Ressalta-se ainda, que uma alta amostragem

---

<sup>1</sup> Por ser de uso já consagrado em português, será adotada a sigla em inglês para representar o termo “imagem funcional por ressonância magnética”.

<sup>2</sup> Sigla em inglês, conhecida em português como contraste “dependente no nível de oxigênio no sangue” (DNOS).

nas condições de atividade e de repouso, aumenta as chances de detecção do sinal durante a execução de tarefas específicas. Consequentemente, é de importância que a técnica seja realizada através de seqüência rápidas de pulsos.

## CAPÍTULO 3. ANÁLISE DE COMPONENTES

### 3.1. ANÁLISE DE COMPONENTES INDEPENDENTES

Este capítulo introduz o conceito de análise de componentes independentes (ACI), fornecendo o suporte teórico e a terminologia utilizada no presente estudo. Será apresentado o modelo estatístico, sobre o qual a ACI foi baseada, juntamente com a sua definição, suas ambigüidades e, suas conseqüências. Finalmente, mostra-se um exemplo de aplicação da ACI, no caso de sinais unidimensionais, para a resolução de problemas na separação cega de fontes (SCF).

A notação matemática utilizada é a seguinte:

- Variáveis aleatórias representadas por letras maiúsculas; e, suas concretizações representadas por letras minúsculas.
- Vetores aleatórios representados por letras maiúsculas em negrito; e, suas concretizações representadas por letras minúsculas também em negrito.

Dado que as matrizes também são representadas por letras maiúsculas em negrito, gerou-se uma ambigüidade com relação às representações de matrizes e vetores aleatórios. Portanto, para evitar tal ambigüidade foi adotada a indicação expressa no texto.

#### 3.1.1. Modelo estatístico e definição

Considerando que  $\mathbf{S} = [S_1, S_2, \dots, S_M]^T$  é um vetor aleatório com  $M$  componentes/fontes estatisticamente independentes entre si, as fontes  $S_i$  serão chamadas de componentes independentes (**Ferreira 2002**). Assim, a função densidade de probabilidade (fdp) multivariada do vetor  $\mathbf{S}$  é dada pelo produto das  $M$  fdps marginais  $p(S_i)$  de todas as componentes independentes:

$$p(\mathbf{S}) = \prod_{i=1}^M p(S_i) = p(S_1)p(S_2)\dots p(S_M). \quad (1)$$

Supondo que sobre o vetor  $\mathbf{S}$  seja aplicado a uma transformação linear  $\mathbf{A}$  (sendo  $\mathbf{A}$  uma matriz de dimensão  $N \times M$ ), será obterá o vetor aleatório  $\mathbf{X} = [X_1, X_2, \dots, X_N]^T$  com  $N$  componentes  $X_i$ , designadas aqui de observações:

$$\mathbf{X} = \mathbf{AS}. \quad (2)$$

O processo de mistura das fontes primárias  $S_i$  pode ter diferentes modelos físicos ou matemáticos, dependendo das aplicações específicas. Portanto, o presente estudo considerará uma abordagem do tipo mistura linear definida pela Equação (2). Para simplificar a apresentação considera-se que  $N = M$ , ou seja, que o número de observações é igual ao número de fontes (onde a matriz  $\mathbf{A}$  é quadrada). Assim, a Equação (2) será representada através de (**James and Hesse 2005**):

$$\mathbf{X} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_M \end{bmatrix} = \begin{bmatrix} a_{11}S_1 + a_{12}S_2 + \dots + a_{1M}S_M \\ a_{21}S_1 + a_{22}S_2 + \dots + a_{2M}S_M \\ \vdots \\ a_{M1}S_1 + a_{M2}S_2 + \dots + a_{MM}S_M \end{bmatrix}. \quad (3)$$

Verifica-se que cada observação  $X_i$  é uma combinação linear de  $M$  componentes independentes  $S_j$ . Analisando as combinações lineares que formam as observações  $X_i$ , observa-se que estas não são estatisticamente independentes entre si. Da mesma forma, as componentes independentes  $S_j$  não são diretamente observáveis. De fato, tanto a matriz de mistura  $\mathbf{A}$  como as componentes independentes  $S_j$  são desconhecidas, sendo as observações  $X_i$  as únicas conhecidas.

Os coeficientes da combinação linear gerados por  $X_i$  constituem a linha  $i$  da matriz  $\mathbf{A}$ :

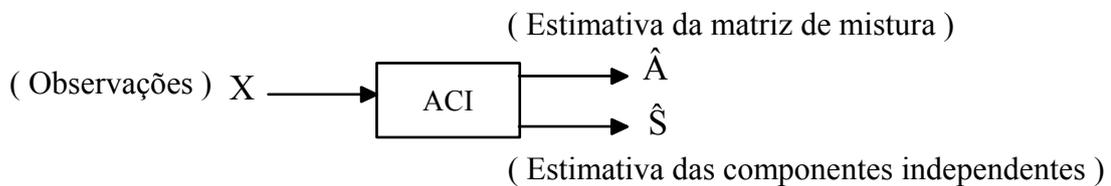
$$X_i = a_{i1}S_1 + a_{i2}S_2 + \dots + a_{iM}S_M = \sum_{j=1}^M a_{ij}S_j, \quad \forall i \in \{1, \dots, M\}. \quad (4)$$

Onde  $\mathbf{a}_i = [a_{i1}, \dots, a_{iM}]^T$  é o vetor que contém os elementos da linha  $i$  da matriz  $\mathbf{A}$ . Assim, a observação  $X_i$  resulta do produto interno de  $\mathbf{a}_i$  por  $\mathbf{S}$ ,

$$X_i = \mathbf{a}_i^T \mathbf{S}. \quad (5)$$

Considerando o modelo da equação supracitada, representada pela Equação (2) e, dado que apenas se observam amostras do vetor  $\mathbf{X}$  - estimação das componentes independentes  $\mathbf{S}$ , e/ou da matriz de mistura  $\mathbf{A}$  - para nosso caso, este será denominado de análise de componentes independentes (ACI).

A ACI tem por finalidade realizar a estimação, de esta forma: a independência estatística entre todas as fontes é a única condição imposta desde sua formulação. A Figura 2, a continuação, esquematiza o processo de estimação da ACI (**Ferreira 2002**).



**Figura 2 :** Diagrama de blocos da estimação da ACI.

Analicamente, a ACI permite estimar a transformação linear  $\mathbf{W}$ , a qual quando aplicada às observações  $\mathbf{X}$  gera componentes estatisticamente independentes:

$$\hat{\mathbf{S}} = \mathbf{W}\mathbf{X} = \mathbf{W}\mathbf{A}\mathbf{S} \quad (6)$$

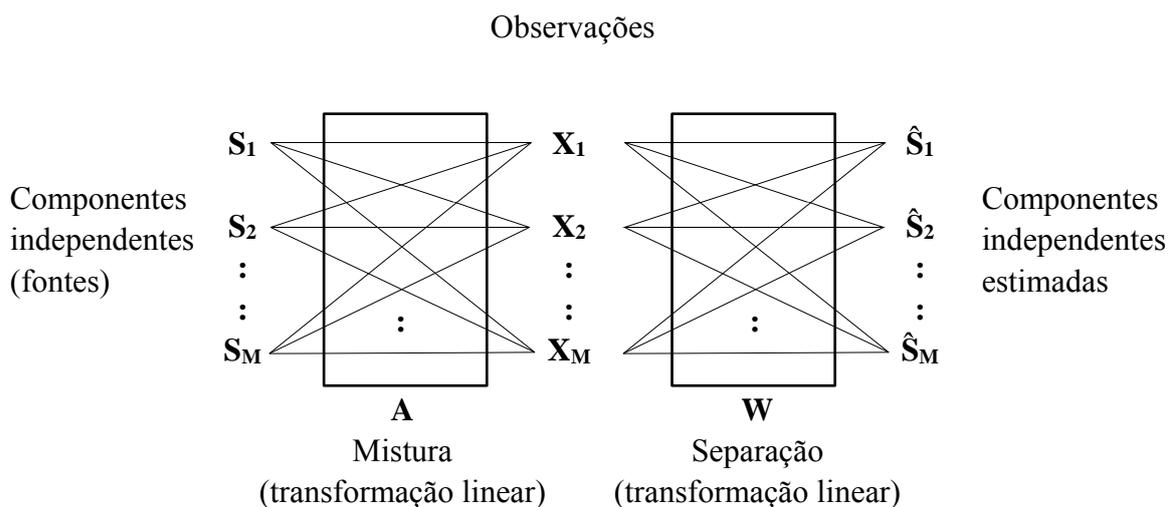
Outra definição para a Equação (6) é: “Encontrar um sistema linear de coordenadas não ortogonais  $\mathbf{W}$  que represente dados multivariados, tal que a representação desses dados pelo sistema  $\mathbf{W}$  seja realizada por coeficientes estatisticamente independentes”. Após a

estimação de  $\mathbf{W}$  obtém-se a matriz de mistura  $\mathbf{A} = \mathbf{W}^{-1}$ , recuperando assim, as componentes independentes  $\hat{S}_i$  a partir das observações  $\mathbf{X}$  segundo:

$$\begin{bmatrix} \hat{S}_1 \\ \hat{S}_2 \\ \vdots \\ \hat{S}_M \end{bmatrix} = \mathbf{W} \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_M \end{bmatrix} = \begin{bmatrix} w_{11}X_1 + w_{12}X_2 + \dots + w_{1M}X_M \\ w_{21}X_1 + w_{22}X_2 + \dots + w_{2M}X_M \\ \vdots \\ w_{M1}X_1 + w_{M2}X_2 + \dots + w_{MM}X_M \end{bmatrix} \quad (7)$$

Dado que apenas se conhecem as observações e se pretende estimar a matriz de mistura e as componentes independentes, não é possível uma solução analítica fechada na ACI. A estimação da transformação linear  $\mathbf{W}$  é realizada através de algoritmos iterativos de otimização, os quais minimizam ou maximizam a função de custo.

A Figura 3 mostra a transformação direta  $\mathbf{A}$  e a transformação inversa  $\mathbf{W}$ , ou seja, a aplicação do sistema de mistura e viceversa. As componentes independentes ou fontes são combinadas linearmente produzindo as observações  $\mathbf{X} = [X_1, \dots, X_M]^T$ , a essas observações é aplicada a transformação linear  $\mathbf{W}$ , obtendo-se as componentes independentes estimadas, designadas por  $\hat{\mathbf{S}} = [\hat{S}_1, \dots, \hat{S}_M]^T$ .



**Figura 3 :** Aplicação do sistema de mistura  $\mathbf{A}$  e viceversa  $\mathbf{W}$  (Ferreira 2002).

### 3.1.2. Ambigüidades do modelo

Analisando a Equação (3) se evidencia que cada observação  $X_i$  é uma combinação linear das componentes independentes, a qual é representada a continuação:

$$\mathbf{X} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_M \end{bmatrix} = \begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{M1} \end{bmatrix} S_1 + \begin{bmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{M2} \end{bmatrix} S_2 + \dots + \begin{bmatrix} a_{1M} \\ a_{2M} \\ \vdots \\ a_{MM} \end{bmatrix} S_M \quad (8)$$

No caso da Equação (8) é possível a constatação de duas ambigüidades no modelo da ACI (Comon 1994):

1. Escalamento: as variâncias das componentes independentes não podem ser estimadas; de fato, efetuar a multiplicação das componentes independentes  $S_j$  por uma constante  $k$  e, simultaneamente efetuar a divisão da respectiva coluna da matriz  $\mathbf{A}$ , pela mesma constante, não altera nenhuma observação  $X_i$ ;
2. Permutação: a ordem das componentes independentes não pode ser estimada, dado que a troca da ordem dos termos da equação (8), não altera nenhuma observação  $X_i$ .

Conseqüentemente, quando combinadas as duas ambigüidades, é possível afirmar que as componentes independentes são estimadas a menos de um escalamento  $\mathbf{T}$  e, de uma permutação  $\mathbf{R}$ .

$$\mathbf{S} = \mathbf{TRWX} \quad (9)$$

Na Equação (9),  $\mathbf{R}$  é uma matriz de permutação, ou seja, para cada linha/coluna, existe apenas um elemento de valor 1, não existindo duas linhas/colunas iguais; onde,  $\mathbf{T}$  é uma matriz de escalamento, com elementos diferentes de zero, ao longo da diagonal principal.

A chamada matriz de desempenho  $\mathbf{P} = \mathbf{TR}$  traduz a qualidade de separação das componentes independentes, refletindo as ambigüidades de estimação por ACI. Após uma reordenação e uma normalização, quanto mais próxima  $\mathbf{P}$  encontra-se da matriz identidade

$\mathbf{I}_M$ , maior será a qualidade da separação. Quando  $\mathbf{P} = \mathbf{I}_M$  sem reordenação nem normalização gerasse uma separação ideal, sem ambigüidades, das componentes  $\mathbf{S}$ , ou seja, mantendo a ordem pela qual foram combinadas e onde não foram utilizados fatores de escala.

Combinando-se as duas equações, (2) e (9) obteve-se

$$\mathbf{S} = \mathbf{TRWAS} = \mathbf{PWAS}. \quad (10)$$

Na separação, onde  $\mathbf{P} = \mathbf{I}_M$  a matriz estimada  $\mathbf{W}$  é exatamente inversa a  $\mathbf{A}$ . Em geral, estas duas ambigüidades da ACI não têm grande impacto nos resultados. Por outro lado o escalamento, através da multiplicação pela constante, preserva o formato dos sinais, não sendo de importância a ordem com que as componentes independentes ou fontes são estimadas, considerando que a finalidade é recuperar as fontes.

### 3.1.3. Separação cega de fontes

As equações (6), (7) e a Figura 3 estabelecem a ligação entre a ACI e o problema de separação cega de fontes (SCF) (Ferreira 2002). Entende-se por separação, ao processo através do qual é possível obter fontes originais  $\mathbf{S}$ , a partir de um conjunto de observações  $\mathbf{X}$ . Este processo é considerado como separação cega devido a não assumir conhecimento sobre as distribuições de probabilidade das fontes  $\mathbf{S}$  e, por ser a matriz  $\mathbf{A}$  de mistura desconhecida.

Inicialmente o desenvolvimento da ACI teve como objetivo resolver o problema da SCF. Atualmente é o método mais utilizado para realizar SCF, sendo ambos termos utilizados na literatura como sinônimos.

Mostraremos a continuação um exemplo de SCF baseado no problema *cocktail-party*, para tal o enunciado é: “Em um salão encontram-se pessoas conversando, simultaneamente, e com música de fundo. O som da sala será captado por dois microfones em locais diferentes. A

finalidade neste contexto é separar os sinais da fala e da música, obtidas mixturadas através dos microfones.” (Comon 1994)

Desta forma, considerando o modelo ACI, o problema *cocktail-party* é representado por:

$$\mathbf{X} = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} S_1 \\ S_2 \end{bmatrix} = \begin{bmatrix} a_{11}S_1 + a_{12}S_2 \\ a_{21}S_1 + a_{22}S_2 \end{bmatrix}. \quad (6)$$

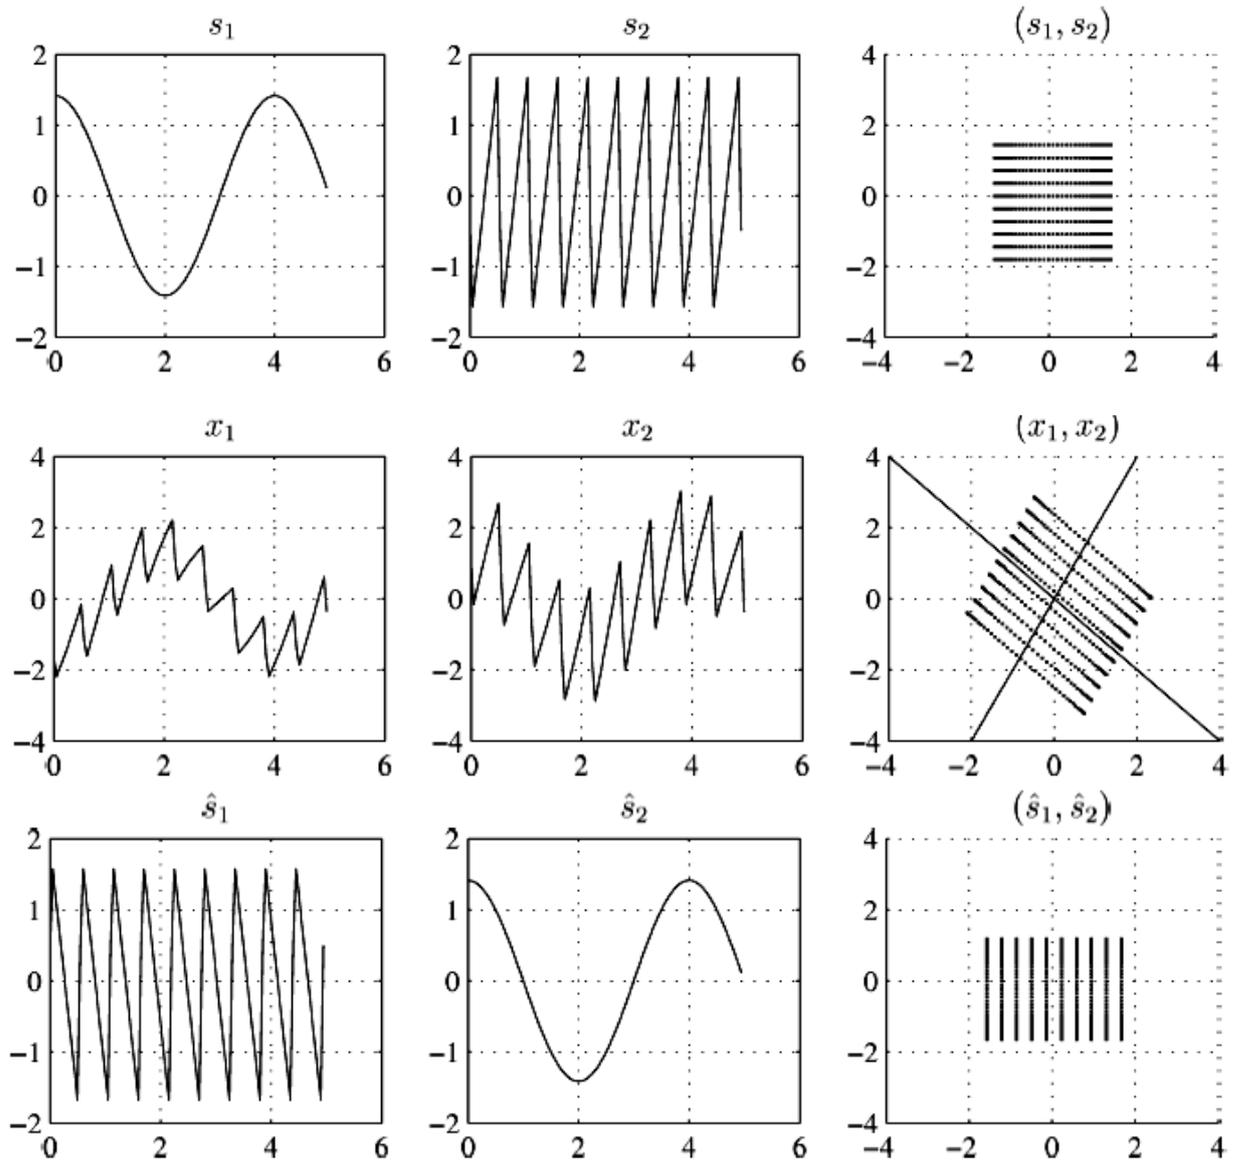
As constantes  $a_{ij}$  representam a atenuação/amplificação aplicada sobre as fontes  $S_1$  e  $S_2$ . A Figura 4, com sinais artificiais, ilustra a aplicação da ACI na resolução deste problema e exemplifica as suas ambigüidades. Os sinais são mostrados no domínio tempo com as concretizações conjuntas. Utilizou-se para tal finalidade a matriz de mistura original:

$$\mathbf{A} = \begin{bmatrix} -1 & 1/2 \\ 1 & 1 \end{bmatrix} \quad (7)$$

Na Figura 4 constata-se que  $S_1$  e  $S_2$  são independentes e,  $X_1$  e  $X_2$  dependentes. As componentes são estimadas com exatidão, a menos de um fator de escala, como consequência das ambigüidades discutidas anteriormente. Assim, a matriz de mistura estimada é:

$$\hat{\mathbf{A}} = \begin{bmatrix} -0.5003 & -0.9999 \\ -0.9996 & 1.0001 \end{bmatrix} \quad (8)$$

Comparando com a matriz original de mistura na equação (7), denota-se que as colunas foram modificadas, sendo a primeira coluna da matriz  $\hat{\mathbf{A}}$  multiplicada por  $-1$ , ou seja, a primeira componente estimada  $\hat{S}_1$  sofreu inversão de fase, como observado nos sinais estimados da Figura 4.



**Figura 4 :** Aplicação da ACI ao problema da SCF. A figura mostra os sinais no domínio tempo e as concretizações conjuntas. Na parte superior observa-se as duas componentes independentes  $s_1$  e  $s_2$ ; no meio, as duas observações  $x_1$  e  $x_2$ , onde as concretizações formam um paralelogramo de arestas, paralelas às retas definidas pelas colunas da matriz A; e, na parte inferior, as componentes estimadas  $\hat{s}_1$  e  $\hat{s}_2$  (Ferreira 2002).

Quanto a separação de sinais de áudio, estas ambigüidades não constituem problema. Foi observada uma perda na informação da amplitude original, porém os sinais foram reconhecidos. Por outro lado, a inversão de fase não foi ouvida pelos indivíduos. Portanto, a ordem da estimação não influenciou na obtenção de sinais separados. Assim, a matriz de desempenho  $\mathbf{P}$ , estimada é:

$$\mathbf{P} = \begin{bmatrix} 0.0003 & 0.9999 \\ -0.9999 & 0.0002 \end{bmatrix} \approx \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}. \quad (9)$$

Esta equação mostra que as duas componentes foram estimadas na ordem contrária à sobrepostas, ainda, a primeira componente foi multiplicada por  $-1$ .

### 3.1.4. Limitações da ACI

A ACI, a partir de observações dependentes, procura estimar as componentes independentes que a originaram e/ou a própria matriz de mistura, para posteriormente, a distribuição conjunta, ser fatorizada. No entanto, existem algumas situações onde não é possível estimar as componentes independentes. Assim, nos casos, onde as distribuições conjuntas das observações são simétricas, a informação pode ser inferida baseada na matriz de mistura  $\mathbf{A}$ .

Desta forma, nas observações anteriores que apresentam concretizações conjuntas em forma de paralelogramo, com arestas paralelas às retas definidas pelas colunas da matriz  $\mathbf{A}$ , caso não traduzam informação sobre a matriz de mistura, estas podem ser estimadas utilizando esta técnica.

Uma outra limitação da ACI, relacionada com a distribuição estatística das componentes independentes, é a propriedade de uma única componente independente ter distribuição normal.

### 3.1.5. Necessidade de pré-processamento

Em geral, a estimação das componentes independentes é simplificada, com algoritmos que convergem de forma rápida, se as observações  $\mathbf{X}$  possuírem média nula e branqueamento (Hyvarinen and Oja 2000):

- $E\{\mathbf{X}\} = 0$ ;
- $\mathbf{C}_X = \text{cov}(\mathbf{X}) = E\{\mathbf{X}\mathbf{X}^T\} = \mathbf{I}$

Na prática, o valor médio pode também ser estimado como uma componente independente. Quando transformadas as observações em média nula, as componentes independentes também são nulas, como observado no modelo ACI da equação (2). Assim, centrar as observações  $\mathbf{X}$  em torno do vetor média  $\mathbf{m}_x = E\{\mathbf{X}\}$  permite obter novas observações:

$$\tilde{\mathbf{X}} = \mathbf{X} - \mathbf{m}_x \quad (10)$$

É conhecido que a imposição da média nula não afeta a matriz de mistura. Assim, após a estimação da matriz de mistura  $\mathbf{A}$  e das componentes independentes  $\mathbf{S}$  com os dados centrados é possível repor o valor médio das mesmas:  $\mathbf{m}_s = \mathbf{A}^{-1}\mathbf{m}_x$ .

Por outro lado, para realizar o branqueamento dos dados aplica-se uma transformação linear invertível  $\mathbf{V}$ , de forma que as observações  $\mathbf{Z} = \mathbf{V}\tilde{\mathbf{X}}$  tenham a matriz de covariância identidade, ou seja, não se correlacionem com a variância unitária:

$$\mathbf{C}_z = \text{cov}(\mathbf{Z}) = E\{\mathbf{Z}\mathbf{Z}^T\} = E\{\mathbf{V}\tilde{\mathbf{X}}(\mathbf{V}\tilde{\mathbf{X}})^T\} = \mathbf{V}E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\}\mathbf{V}^T = \mathbf{I} \quad (11)$$

Quanto a matriz de covariância das observações  $\tilde{\mathbf{X}}$ , designada por  $\mathbf{C}_{\tilde{x}}$ , esta é simétrica, portanto, seus autovetores são ortogonais entre si e, os seus autovalores são reais:

$$\mathbf{C}_x = E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\} = \mathbf{E}\mathbf{D}\mathbf{E}^T \quad (12)$$

Onde,  $\mathbf{E}$  é a matriz ortogonal cujas colunas são autovetores normalizados de  $E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\}$  e,  $\mathbf{D} = \text{diag}(d_1, \dots, d_n)$  é a matriz diagonal com os autovalores de  $\mathbf{C}_{\tilde{x}}$ , sendo o branqueamento baseado na transformação linear invertível não ortogonal:

$$\mathbf{V} = \mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T \quad (13)$$

Considerando a definição de  $\mathbf{V}$  e a decomposição em autovalores, apresentada na equação (12), tem-se:

$$\begin{aligned}
\mathbf{C}_Z &= \text{cov}(\mathbf{Z}) = E\{\mathbf{Z}\mathbf{Z}^T\} = E\{\mathbf{V}\tilde{\mathbf{X}}(\mathbf{V}\tilde{\mathbf{X}})^T\} = E\{\mathbf{V}\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\mathbf{V}^T\} \\
&= \mathbf{V}E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\}\mathbf{V}^T = (\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T)(\mathbf{E}\mathbf{D}\mathbf{E}^T)(\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T)^T \\
&= \mathbf{D}^{-\frac{1}{2}}\underbrace{\mathbf{E}^T\mathbf{E}}_{\mathbf{I}}\underbrace{\mathbf{E}\mathbf{D}\mathbf{E}^T}_{\mathbf{I}}\mathbf{D}^{-\frac{1}{2}} = \mathbf{D}^{-\frac{1}{2}}\mathbf{D}\mathbf{D}^{-\frac{1}{2}} = \mathbf{I}
\end{aligned} \tag{14}$$

Contudo,  $\mathbf{V}$  não é a única matriz de branqueamento, sendo que, qualquer matriz  $\mathbf{UV}$ , onde  $\mathbf{U}$  seja ortogonal, conduz ao mesmo resultado.

Observa-se que a utilidade da operação de branqueamento é a transformação da matriz de mistura  $\mathbf{A}$ , na matriz  $\tilde{\mathbf{A}}$ . Assim, unificando as equações (2) e (13) e, considerando que as observações têm média nula tem-se:

$$\mathbf{Z} = \mathbf{V}\tilde{\mathbf{X}} = \underbrace{\mathbf{V}\mathbf{A}}_{\tilde{\mathbf{A}}}\mathbf{S} = \mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T\mathbf{A}\mathbf{S} = \tilde{\mathbf{A}}\mathbf{S}. \tag{15}$$

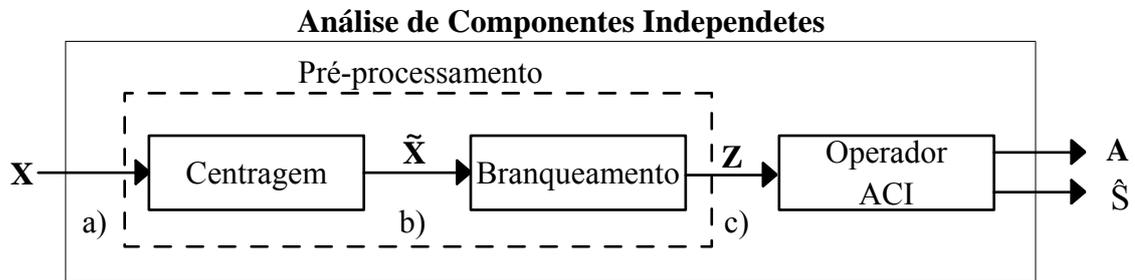
E, sabendo que  $\mathbf{C}_Z = \mathbf{I}$ , temos:

$$\mathbf{I} = E\{\mathbf{Z}\mathbf{Z}^T\} = E\{\tilde{\mathbf{A}}\mathbf{S}(\tilde{\mathbf{A}}\mathbf{S})^T\} = \tilde{\mathbf{A}}E\{\mathbf{S}\mathbf{S}^T\}\tilde{\mathbf{A}}^T = \tilde{\mathbf{A}}\tilde{\mathbf{A}}^T = \mathbf{I}. \tag{16}$$

Portanto, a nova matriz de mistura  $\tilde{\mathbf{A}}$  é ortogonal. Desta forma, como observado, o branqueamento reduz o número de parâmetros a estimar; e, o espaço de pesquisa das matrizes ortogonais. Assim, em vez de estimar os  $n^2$  parâmetros (elementos) de uma matriz de mistura genérica  $n \times n$ , será necessário estimar  $\frac{n(n-1)}{2}$  parâmetros, dado que, este é o número de graus de liberdade de uma matriz ortogonal. Para valores elevados de  $n$ , constata-se que cerca da metade dos graus de liberdade são da matriz arbitrária.

Emfim, o branqueamento é uma forma adequada de reduzir a complexidade do problema da estimação, nas componentes independentes. Considerando que, após o branqueamento, a matriz de covariância dos dados é diagonal, e as estatísticas de segunda ordem ficam removidas, o qual permite, que o operador de ACI direcione sua análise em estatísticas de ordem superior.

A Figura 5 ilustra as fases de pré-processamento e aplicação do operador de ACI, através de diagramas de blocos, durante todo o processo de estimação (Ferreira 2002).



**Figura 5 :** Diagrama de blocos da ACI; detalhe sobre o pré-processamento.

De acordo com a notação introduzida na Figura 5, temos:

- a) As observações:  $\mathbf{X}$ .
- b) As observações centradas, com médias nulas e correlacionadas:  $\tilde{\mathbf{X}} = \mathbf{X} - \mathbf{m}_x$ .
- c) As observações branqueadas (centradas e não correlacionadas com variância unitária):

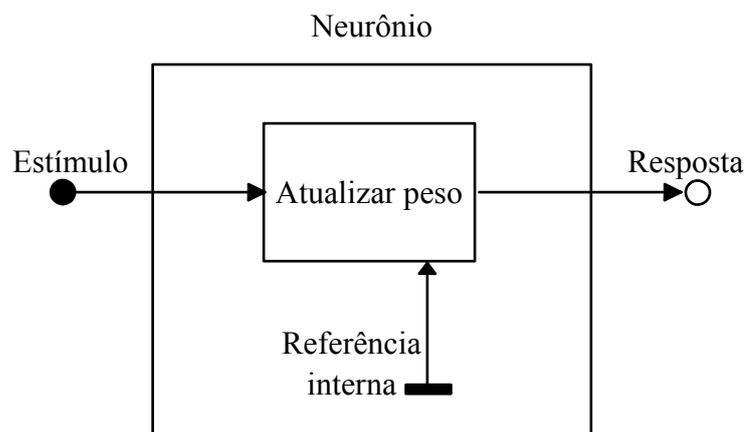
$$\mathbf{Z} = \mathbf{V}\tilde{\mathbf{X}}.$$

### 3.2. ANÁLISE DE COMPONENTES DEPENDENTES

O presente estudo buscou utilizar um unico algoritmo, para SCF, que incorpore estratégias na solução de problemas de permutação e de ambigüidade, existentes para a ACI. Uma das características desejadas para o novo algoritmo é que ele possa utilizar sinais não ortogonais (Barros and Cichocki 2002), ou seja, que possa relaxar a suposição de independência estatística entre as fontes, através de estratégia que diminuam a redundância, onde os sinais de saída devem ter uma medida mínima de correlação cruzada.

Desta forma, para diferenciar o novo método da ACI, ele será denominado de análise de componentes dependentes (ACD) (Barros and Cichocki 2002; de Araujo et al. 2005; Estombelo-Montesco et al. 2007b; Estombelo-Montesco et al. 2007a).

Alguns algoritmos propostos na literatura usam o chamado aprendizagem de tipo ponto-fixo, onde é extraído um sinal por vez. Assim, o método de aprendizagem utilizado nesse trabalho alicerça-se neste tipo de aprendizagem,, sendo a diferença dada pela informação a priori requerida e, pela extração da componente (função base) de forma direta durante a varredura de dados. Esta é uma função realizada através da entrada de uma referência interna, no caso a hipótese, que assume ser da própria unidade processadora, ou neurônio, como mostrado na Figura 6. Neste caso, se presume que a entrada dessa referência pode ser um padrão que pertenceu previamente ao neurônio, considerando sua adaptação ao ambiente e suas características genéticas.



**Figura 6 :** Modelo para o neurônio que inclui uma referencia interna (ou padrão)(Barros and Cichocki 2002).

### 3.2.1. Separação da fonte pela ACD

Considerando a disponibilidade do vetor  $\mathbf{X}$ , assim como a necessidade de desenvolver algoritmos que permitam estimar as fontes primárias e/ou identificar a matriz de mistura  $\mathbf{A}$  - com algumas ambigüidades intrínsecas (fatores de escalamento e permutação)- a literatura mostra a aplicação de duas abordagens principais na solução do problema. A primeira abordagem permite a separação simultânea de todas as fontes primárias; e, a segunda a extração das fontes primárias uma a uma, sequencialmente, em vez de se extrair todas de forma simultanea (Cichocki et al. 2002).

Inumeras aplicações encontram-se disponíveis para um grande número de sensores, porém somente alguns sinais fonte são de interesse, sendo o restante considerado ruído de interferência. Para o caso do problema *cocktail-party*, onde é essencial extrair a voz específica de um único indivíduo, em vez de separar todos os sinais fonte disponíveis a partir do vetor de sinais, é necessário desenvolver algoritmos de aprendizagem confiáveis, robustos e efetivos que permitam extrair apenas os sinais fonte de interesse (**Barros et al. 2000**).

Nesse contexto, e focando o objetivo do presente estudo, a continuação será descrita a estratégia de algoritmo proposta (**Barros and Cichocki 2001**), considerando que será a partir deste momento o alicerce para a aplicação de dados reais a serem utilizados em diversos contextos (**de Araujo et al. 2005; Estombelo-Montesco et al. 2007b; Estombelo-Montesco et al. 2007a**).

Sendo o sinal fonte  $\mathbf{S}(k) = [s_1(k), \dots, s_n(k)]^T$ , onde  $n$  fontes encontram-se dispostas, o vetor observado  $\mathbf{X}(k) = [x_1(k), \dots, x_n(k)]^T$  é o resultado da mistura linear dos sinais fonte. Dessa forma, e com o objeto de encontrar a componente de  $\mathbf{X}$  gerada a partir das fontes de interesse  $s_i(k)$ , essa mistura pode ser escrita como  $\mathbf{X}(k) = \mathbf{A}\mathbf{S}(k)$ , onde  $\mathbf{A}$  é uma matriz  $n \times n$  não singular (invertível). Portanto, como mostrado no capítulo anterior, o número de componentes independentes pode ser tão grande como a dimensão do vetor  $\mathbf{X}$ .

Nesta abordagem, assume-se que os sinais fonte têm uma estrutura temporal e funções de autocorrelação diferentes, sem necessariamente ser estatisticamente independentes. Deve-se observar que essa ausência de correlação mútua, em um período de tempo, é suficiente, mas não necessária, para poder extrair a fonte com sucesso. Devido a atrasos temporais específicos em cada sinal,  $\tau_i$ , o algoritmo garante a extração de forma cega de qualquer um dos sinais fonte  $s_i$  que cumpra as seguintes relações:

$$E[s_i(k)s_i(k - \tau_i)] \neq 0 \quad (17)$$

$$E[s_i(k)s_j(k - \tau_i)] = 0 \forall i \neq j.$$

Como o objetivo é extrair um unico sinal fonte, poderá ser utilizada uma unidade de processamento simples, descrita através de  $y(k) = \mathbf{w}^T \mathbf{x}(k)$ , onde  $y(k)$  é o sinal de saída (estimativa do sinal fonte específico  $s_i$ ),  $k$  é o número da amostragem, e  $\mathbf{w}$  é o vetor de pesos. Seguidamente, deverá ser definida a seguinte medida de erro:  $\varepsilon(k) = y(k) - y(k - p)$ , tendo em vista desenvolver o algoritmo

### 3.2.2. Algoritmo de aprendizagem

A idéia principal é realizar a minimização do erro quadrático médio (EQM)  $\xi(\mathbf{w}) = E[\varepsilon^2]$ . Assim, será simplificada a notação  $y_p = y(k - p)$ , onde o sub-índice  $p$  é usado para representar o atraso temporal e, o índice  $k$  será omitido por conveniência. Dessa forma após algumas manipulações matemáticas obteve-se:

$$\xi(\mathbf{w}) = \mathbf{w}^T E[\mathbf{x}\mathbf{x}^T] \mathbf{w} - 2E[y_p \mathbf{w}^T \mathbf{x}] + E[y_p^2]. \quad (18)$$

A função de custo (18) quando comparada com  $\mathbf{w}$  alcança seu mínimo, se seu gradiente chegar a zero. Então, para alcançar o mínimo será aplicada a seguinte condição:

$$\frac{\partial \xi(\mathbf{w})}{\partial \mathbf{w}} = 2E[\mathbf{x}\mathbf{x}^T] \mathbf{w} - 2E[y_p \mathbf{x}] + 2E[\mathbf{x}_p \mathbf{x}_p] \mathbf{w} = 0. \quad (19)$$

Isso resulta na seguinte regra de atualização:

$$\mathbf{w} = \frac{1}{2} E[\mathbf{x}\mathbf{x}^T]^{-1} E[y_p \mathbf{x}]. \quad (20)$$

Sem perda de generalidade, pode-se assumir que os dados foram pré-branqueados, assumindo que  $E[\mathbf{x}\mathbf{x}^T] = \mathbf{I}$ . Dessa forma, a normalização do vetor para cada iteração, na forma  $\mathbf{w}_* = \mathbf{w} // \|\mathbf{w}\|$ , leva à seguinte regra de aprendizado (**Barros and Cichocki 2001**):

$$\mathbf{w} = E[\mathbf{x}y_p]. \quad (21)$$

Surgindo assim a seguinte questão: **como estimar um atraso temporal mais eficiente?** Uma simples solução é calcular a função de correlação dos sinais do sensor como função do atraso, e encontrar o atributo correspondente, ou seja, um pico com o atraso apropriado, que corresponda ao sinal de interesse. Para tal finalidade, o sistema será modelado usando a auto-regressão, que será descrita em seções seguintes.

### 3.2.3. Evitando a Permutação

Segundo o capítulo anterior, algoritmos que realizam a estimativa de todas as componentes de forma cega - usando a matriz  $\mathbf{W}$  de  $n \times n$  componentes, e obtendo na saída o vetor  $\mathbf{Y} = \mathbf{WX} = \mathbf{WAS}$  - possuem uma ambigüidade de escala e ordem que pode ser representada por  $\mathbf{Y} = \mathbf{DPS}$ , onde  $\mathbf{D}$  e  $\mathbf{P}$  são a matriz diagonal e a matriz de permutação, respectivamente (Comon 1994).

Utilizando o raciocínio anterior e na tentativa de estimar uma componente por vez, a ambigüidade mencionada pode ser escrita como:  $y = \alpha \mathbf{P}^T \mathbf{S}$ , onde  $\mathbf{P}$  é qualquer coluna da matriz de permutação e  $\alpha$  é um fator de escalamento. Portanto, não pode ser predita a ordem da estimação das componentes.

No entanto, acredita-se que a permutação pode ocorrer se a intenção é recuperar as fontes de forma cega. De fato, com o teorema mostrado (Barros and Cichocki 2001) comprova-se que o algoritmo da equação (21) soluciona o problema de permutação e conduz à extração da componente desejada.

### 3.2.4. Evitando o problema de escalamento

A estimativa do sinal extraído pelo método ACD pode ser multiplicada por um fator de escala no processo final da extração. No entanto, caso a avaliação da estimativa do sinal não dependa de medidas prévias, o escalamento do sinal será considerado como problema se o sinal fonte obtido e, seu comportamento são relevantes. Por outro lado, na presença de medidas de

controle, quando o propósito é avaliar o sinal extraído antes e após algum evento (ou tarefa), com posterior comparação, o problema de escalamento é considerado relevante. Em consequência, se não tratarmos o problema de escalamento adequadamente o resultado final, da comparação, pode levar a uma avaliação errônea.

Considerando a formulação para o problema de permutação temos  $y = \alpha \mathbf{P}^T \mathbf{S}$ , onde  $\alpha$  é um fator de escalamento que precisa ser estimado, quando simplificado  $\mathbf{P}$  é ignorado e iniciada a seguinte formulação  $\mathbf{Y} = \alpha \mathbf{S}$ .

Após a extração da componente desejada através da ACD, será estimado o fator de escalonamento  $\alpha$ . Assim,  $y$  componente extraída, pode voltar a ser projetada no conjunto original de sinais observados. Para tal, será inicialmente definido o seguinte erro:

$$\varepsilon_b = x_i - \alpha_i y. \quad (22)$$

Nesta definição,  $x_i$  é o sinal observado que contem a escala original, e  $y$  é a componente obtida através da ACD. Posteriormente, será minimizado o erro quadrático médio do erro definido  $\xi(\alpha_i) = E[\varepsilon_b^2]$ , obtendo  $\xi(\alpha_i) = x_i^2 - 2x_i \alpha_i y + (\alpha_i y)^2$ . Sendo o mínimo será alcançado fornecendo os seguintes pesos na expressão:

$$\alpha_i = E[y^2]^{-1} E[xy]. \quad (23)$$

A formulação apresentada fornece dois tipos de informação importantes. A primeira relacionada a escolha do maior valor absoluto de  $\alpha$ , onde temos o fator de escalamento para a componente extraída através da ACD, concluindo-se que, existe uma forma de realizar uma comparação das amplitudes relativas do sinal medido antes e após algum evento ou tarefa, nos domínios de tempo ou de frequência do sinal. A segunda menciona que quando comparados todos os valores de  $\alpha$ , podemos obter a contribuição de cada canal para o sinal fonte extraído, permitindo assim, realizar um mapa espacial da distribuição e localização da contribuição do sinal fonte estimado.

### 3.3. MODELO AUTO-REGRESSIVO

O modelo auto-regressivo (AR) é uma das mais importantes técnicas de modelagem matemática, sendo muito utilizado para análise de sinais fisiológicas (**Spyers-Ashby et al. 1998**).

O modelo AR consiste no cálculo de pesos, multiplicados com as entradas anteriores de um determinado ponto do sinal, onde conhecendo os pesos e a variância do ruído é possível calcular o espectro de potência do ponto. O modelo permite estimar o valor de um ponto  $x(n)$  em uma série, em função de pontos passados  $x(n-k)$ , onde  $1 < k < p$  e  $p < n$ , daí a denominação de auto-regressivo. Atualmente, os estimadores auto-regressivos têm sido bastante utilizados, principalmente pelo fato de fornecerem um espectro de potência de alta resolução, dos pontos estimados da série, em função dos parâmetros calculados.

Através do modelo AR estima-se o ponto  $\tilde{x}(n)$  da seguinte forma:

$$x(n) = \hat{x}(n) + e(n), \quad \text{onde } \hat{x}(n) = -\sum_{k=1}^p a_k x(n-k). \quad (24)$$

Nesta equação,  $x(n)$  é o sinal observado,  $\hat{x}(n)$  é o sinal estimado e  $e(n)$  representa o ruído, que tem média zero e variância  $\sigma^2$ . A ordem do estimador, ou do modelo, é o valor de  $p$  na equação anterior.

Portanto, o processo da estimativa consiste em determinar os coeficientes  $a_k$  do modelo AR, abreviado na literatura como  $AR(p)$ , a partir de dados disponíveis ou observados, os que podem ser determinados, através do método de minimização do erro, método de Yule-Walker, que será usado no presente trabalho (**Marple 2005**). A análise adicional também como, a estimativa do espectro, serão calculadas utilizando os parâmetros do modelo, e não através de dados originais.

O espectro de potência da estimativa auto-regressiva é representada pela equação (**Madisetti and Williams 1998; Moraes et al. 2003**):

$$\hat{P}_m(\omega) = \sigma^2 \left| 1 + \sum_{k=1}^p a_{pk} \exp(-i\omega k) \right|^{-2}. \quad (25)$$

Onde,  $\hat{P}_m(\omega)$  é a potência espectral para a frequência  $\omega$  do ponto estimado  $x(m)$  e,  $a_{mk}$  são os coeficientes AR. Neste método, a resolução no espaço de frequências não depende da ordem da estimativa, portanto, não depende do número de pontos a serem utilizados para a determinação do espectro. Assim, os espectros de potência obtidos pelo método AR fornecem melhor resolução na frequência, que quando obtidos pela FFT (transformada rápida de Fourier).

É necessário tomar especial cuidado ao interpretar a estimativa do espectro de potência do sinal, pois, a estimativa é uma função de frequência na faixa de  $0 < f < 1/2 f_{\text{amostragem}}$ . Para os métodos baseados na FFT a altura do pico do espectro é proporcional à potência da correspondente componente nos dados, no caso de métodos baseado em AR a área inferior ao pico é proporcional à potência da componente (Marple 2005).

### 3.3.1. Eleição na ordem do modelo

A importância da escolha na ordem do modelo, não conhecida *a priori*, é fundamental para a representação de dados originais. Na prática, costuma-se postular várias ordens, sendo escolhida aquela que permita calcular algum critério de erro, para ser definido como melhor modelo (Marple 2005). Se ressalta que, valores muito altos na ordem do modelo, embora propiciem um ganho na resolução do espectro, podem causar o fenômeno denominado separação da linha espectral, sendo caracterizado pelo aparecimento de dois picos separados no espectro (falsos picos), considerando que apenas deveria aparecer um. Em contraste, valores muito baixos podem provocar uma estimativa do espectro de forma muito lisa, carecendo de detalhes e, ainda, ocasionando perda de picos.

Vários métodos foram desenvolvidos para auxiliar a escolha da ordem do modelo, dentre eles foi achado um estudo exaustivo e detalhado (**Boardman et al. 2002**) (Falta hacer un resumen del modelo). Atualmente, uma das técnicas mais usadas é o critério de informação de Akaike ou AIC (**Akaike 1974; Marple 2005**), modelo que minimiza a função da teoria da informação, sendo definida como:

$$AIC(p) = N \ln(E_p) + 2p. \quad (26)$$

Onde,  $N$  é o número dados amostrados e  $E_p$  é a potência do erro predito (produzido anteriormente na estimativa dos parâmetros). Segundo o AIC, o valor de  $p$  que minimiza a função acima (em um gráfico de AIC versus  $p$ ) representa a ordem desejada para o modelo (**Spyers-Ashby et al. 1998**).

### 3.4. TRANSFORMADA DE WAVELET

A transformada de *wavelet* de um sinal, também chamada de ondaleta, permite a análise nos domínios de tempo e frequência do sinal. Basicamente, ela é uma representação do sinal construída por translações e dilatações de uma *wavelet* de base  $\Psi$ . Assim, a transformada de *wavelet* contínua de um sinal  $u$ , é calculada a partir do produto interno do sinal com o conjugado complexo da *wavelet* de base  $\Psi$  (**Aldroubi and Unser 1996**):

$$U(b,a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} u(t) \Psi^* \left( \frac{t-b}{a} \right) dt. \quad (27)$$

Onde,  $a, b \in \mathfrak{R}$  e  $a > 0$  é o coeficiente da escala que permite a compressão ou a expansão da função *wavelet*;  $b$  é o coeficiente de translação no eixo do tempo; e,  $\Psi(t)$  é a função da *wavelet* de base, sendo o termo  $\frac{1}{\sqrt{a}}$  o fator de normalização.

Nos sinais discretos, a transformada de *wavelet* do sinal  $u$  é definida como:

$$U(b, a) = 2^{\frac{a}{2}} \sum_k u(k) \Psi(2^{-a} k - b). \quad (28)$$

Sendo que,  $a$  e  $b$  são versões discretas dos coeficientes da escala e da translação, respectivamente, e a função discreta  $\Psi$  pode ser tomada como uma versão amostrada da contraparte contínua.

A *wavelet* de base  $\Psi$  é geralmente escolhida pela boa localização nos domínios de tempo e frequência. Esta função pode ser real ou complexa, resultando também em uma transformada real ou complexa. Quando analisado o sinal, nenhuma escala é privilegiada, pois a mesma função  $\Psi$  é utilizada em diversas escalas, portanto, a transformada mantém uma resposta fortemente dependente da função  $\Psi$  (**Rioul and Vetterli 1991**).

Da mesma forma, esta transformada tem a função de calcular os coeficientes dos espectros de frequência para cada frequência de sinal, ou seja, a energia se dá em função da frequência. O diagrama resultante, de tal cálculo, é denominado espectrograma, sendo que analogamente, as magnitudes da transformada de *wavelet* definem o escalograma da função (**Aldroubi and Unser 1996; Rioul and Vetterli 1991**). Para efeitos do presente estudo este tipo de representação será chamado de representação tempo-frequência (RTF).

### 3.4.1. Transformada de Morlet

A primeira *wavelet* de base, ainda muito usada no contexto da teoria das *wavelets*, foi a *wavelet* de Morlet, também chamada de gaussiana modulada. Esta é a mais apropriada para o análise de padrões periódicos locais, considerando sua boa localização nos domínios de tempo e frequência (**Tallon-Baudry et al. 1997**).

A *wavelet* de Morlet complexa  $w(t, f_0)$  tem a forma de uma onda gaussiana, tanto no domínio de tempo (com desvio padrão  $\sigma_t$ ) como de frequência (com desvio padrão  $\sigma_f$ ),

localizada em sua freqüência central  $f_0$ . Sendo definida pela expressão (Tallon-Baudry et al. 1997):

$$w(t, f_0) = A \exp(-t^2/2\sigma_t^2) \exp(2i\pi f_0 t). \quad (29)$$

Nesta equação, o fator de normalização  $A$  é igual a  $(\sigma_t \sqrt{\pi})^{-1/2}$ , onde o desvio padrão no domínio da freqüência é dado por  $\sigma_f = 1/2\pi\sigma_t$ .

A família da *wavelet* de Morlet é caracterizada pela razão constante  $\tilde{w} = f_0/\sigma_f$ , onde  $\tilde{w}$  é denominada de “largura” da *wavelet*. Quando aplicada em magnetogastrografia, esta família é definida por  $\tilde{w} = f_0/\sigma_f = 3.5$ , com  $f_0$  variando desde 0.02 Hz até 0.09 Hz em passos de 0.001 Hz. Para 0.02 Hz a duração da *wavelet* ( $2\sigma_t$ ) é determinada por 55.70 s e, a largura de banda espectral ( $2\sigma_f$ ) de 0.01 Hz; já para 0.09 Hz, a duração é de 12.38 s e, a largura de banda espectral é de 0.05 Hz. Este exemplo ilustra como a resolução temporal aumenta com a freqüência  $f_0$ , enquanto a resolução na freqüência decresce.

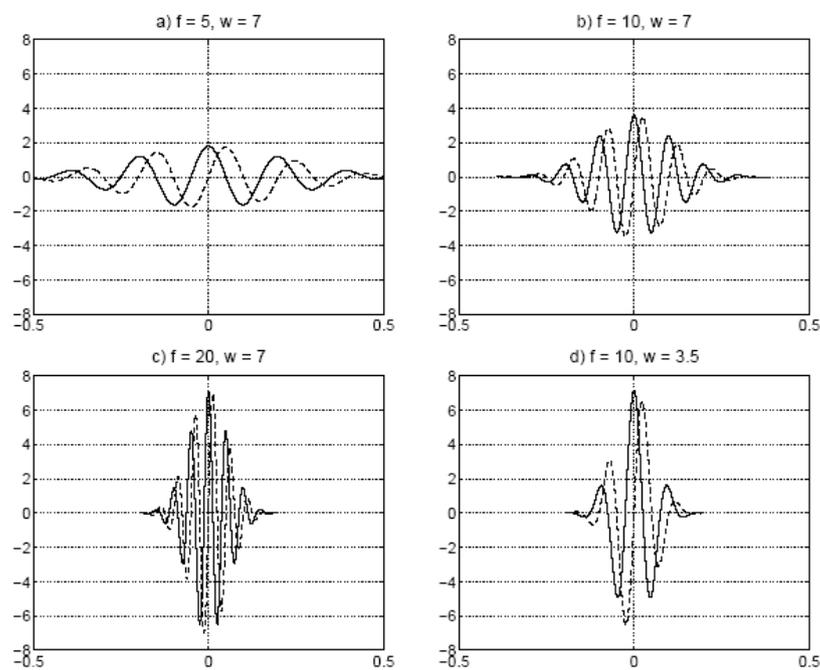
O vetor  $t$  (de  $t_{Inicio}$  até  $t_{Fim}$ ) é a faixa de tempo para a *wavelet*, cujo intervalo de amostragem é  $\Delta t$ , assim é definida a freqüência de amostragem  $f_s$  como  $f_s = 1/\Delta t$ . De fato, a “largura” da *wavelet* não é literalmente uma largura, mas sim o número de oscilações da *wavelet*.

Da mesma forma,  $2\sigma_t$  é igual ao comprimento ou duração da *wavelet* e,  $2\sigma_f$  é igual à largura de banda espectral da *wavelet*, para uma freqüência específica. Considerando que, quando examinada a freqüência,  $f_0$ , determina algumas das propriedades da *wavelet*. Nesse sentido, surge a necessidade de conhecer o que caracteriza a constante  $\tilde{w}$ .

Na Figura 7 se observa que se  $\tilde{w}$  é dividida por dois, sendo também dividido o número de oscilações da função de base, o que torna a largura da *wavelet* mais estreita. Além disso, quanto menor  $\tilde{w}$ , maior será a largura de banda espectral da *wavelet*, indicando que a *wavelet*

processará atividade de uma banda de maior largura. Por outro lado, para maiores valores de  $\tilde{w}$ , a resolução temporal da *wavelet* será de várias centenas de milisegundos, em frequências abaixo de 20 Hz, indicando que componentes de frequências baixas requerem longos registros quando analisadas por este método.

Grandes valores de  $\tilde{w}$  fornecem uma excelente banda larga espectral, porém a resolução temporal não é suficientemente boa, podendo chegar até várias centenas de milisegundos, em especial quando se trata de baixas frequências.



**Figura 7** : Quatro *wavelets* de Morlet diferentes. As *wavelets* mostradas em a), b) e c) têm a mesma “largura”,  $\tilde{w}$ , igual a 7. A largura da banda espectral se amplia quando as frequências são aumentadas. Observado também quando o envelope da *wavelet* se torna mais agudo. Por outro lado, quando  $\tilde{w}$  é dividida pela metade o número de oscilações da *wavelet* também é dividido pela metade, como observado em d). A linha sólida é a parte real da *wavelet* complexa, e a linha tracejada é a parte imaginária.

Algumas propriedades de diferentes *wavelets* de Morlet são mostradas na Tabela 1. A resolução temporal deste método é aumentada com a frequência  $f_0$ , enquanto, a resolução na frequência decresce, o que é observado claramente na Tabela 1 (Auranen 2002).

$\tilde{w}$	$f_0$	$2\sigma_t$ (ms)	$2\sigma_f$ (Hz)
1	5	64	10
1	10	32	20
1	20	16	40
5	5	318	2
5	10	159	4
5	20	80	8
7	5	446	1.4
7	10	223	2.9
7	20	111	5.7
10	5	637	1
10	10	318	2
10	20	159	4

**Tabela 1:** Efeito da "largura",  $\tilde{w}$ , da *wavelet* de Morlet no seu desempenho em diferentes frequências  $f_0$ .  $2\sigma_t$  é a duração da *wavelet* e,  $2\sigma_f$  é a largura da banda espectral da *wavelet* na frequência existente na tabela. Dessa forma, esses valores determinam o ótimo desempenho da *wavelet*.

Finalmente, foram encontradas na literatura várias aplicações usadas com versões modificadas da *wavelet* de Morlet, o que denominaremos de pseudo *wavelets* de Morlet. Embora estas não sejam necessariamente úteis para reconstruir o sinal a partir da transformada de *wavelet* (Sadowsky 1996), elas permitem mostrar a RTF do sinal, pois estes aparecem como padrões na superfície; além de ser bastante simples de serem aplicadas na prática computacional (Sadowsky 1996).

## CAPÍTULO 4. COMPONENTE FETAL A PARTIR DE MAGNETOCARDIOGRAMAS

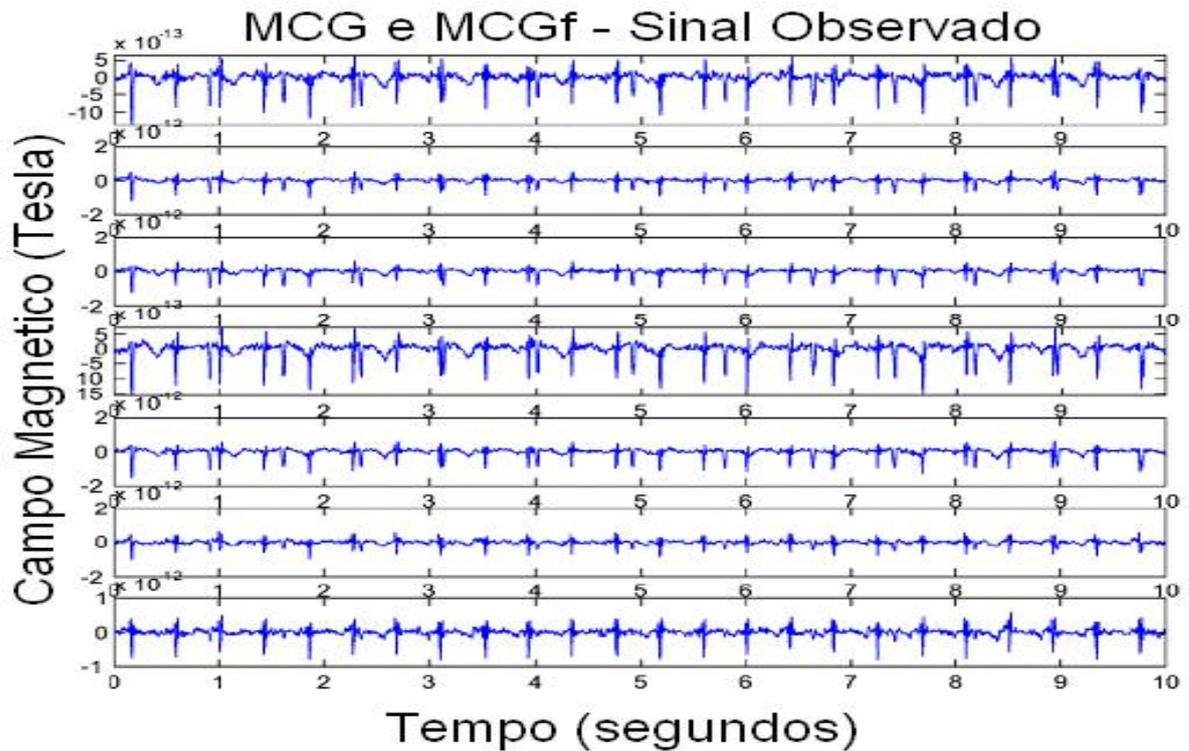
Neste capítulo, descreve uma aplicação do algoritmo de ACD proposto anteriormente para MCGf, onde o sinal de interesse foi extraído usando um atraso temporal  $\tau_i$  obtido da modelagem do sistema por AR e, identificando a componente de interesse no sinal. Os resultados mostram que o método é efetivo na remoção do sinal materno, sendo ressaltada sua eficiência computacional. Finalmente, serão comparados estes resultados com os obtidos através de outro método, conhecido como FastICA (**Hyvarinen and Oja 1997**).

### 4.1. MATERIAL E MÉTODOS

Os dados de MCGf foram coletados de dois fetos assintomáticos de 29 a 32 semanas de gestação. Os registros foram realizados com um biomagnetômetro de 37 canais (Magnes II, 4D Neuroimaging), que coletava os sinais do feto e da mãe, de forma misturada. A coleta dos dados realizada na Universidade de Winsconsin-Madison, UW, Estados Unidos, pelo Prof. O. Baffa da Universidade de São Paulo e, o grupo de pesquisa liderado pelo Prof. Ronal Wakai da Universidade de Winsconsin - Madison. Os sinais foram digitalizados a 520,8 Hz e foram filtrados com passa-banda de 1 a 80 Hz. Esta filtragem, de sinais magnéticos do coração entre 1 e 80 Hz, é uma prática comum em MCGf e não compromete a qualidade dos registros (**Wakai et al. 2003**). Finalmente, os dados foram re-amostrados, de forma a serem trabalhados e digitalizados com uma frequência 4 vezes menor a 130,2 Hz. Para tal, foi utilizada a função *decimate* do MatLab que reamostra e aplica um filtro para evitar erros no processamento.

## 4.2. RESULTADOS

Para ter uma idéia dos dados, a Figura 8 mostra 5 dos 37 canais registrados pelo biomagnetômetro. A figura mostra 10 segundos de dados típicos, onde é observado que o MCG da mãe e o MCG do feto se sobrepõem no tempo.

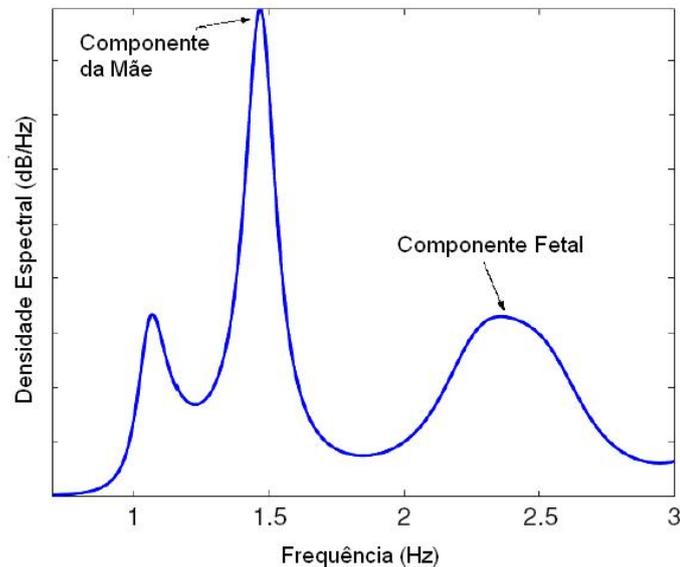


**Figura 8 :** Dez segundos de dados observados, para 5 dos 37 canais de MCGf registrados. Os registros mostram os sinais da mãe e do feto sobrepostos.

O algoritmo proposto no capítulo anterior foi aplicado para extrair o MCGf a partir dos sinais observados. O primeiro passo foi calcular os coeficientes auto-regressivos pelo método de Yule-Waker e, posteriormente, obter as raízes correspondentes dos pólos (Figura 9). A complexidade dos dados de MCGf é devida a que os sinais cardíacos, materno e fetal, são quase-periódicos e são similares.

No entanto, é possível demonstrar com o modelo proposto, que os sinais cardíacos, materno e fetal, são caracterizados por valores diferentes quanto a frequência e amplitude. Na

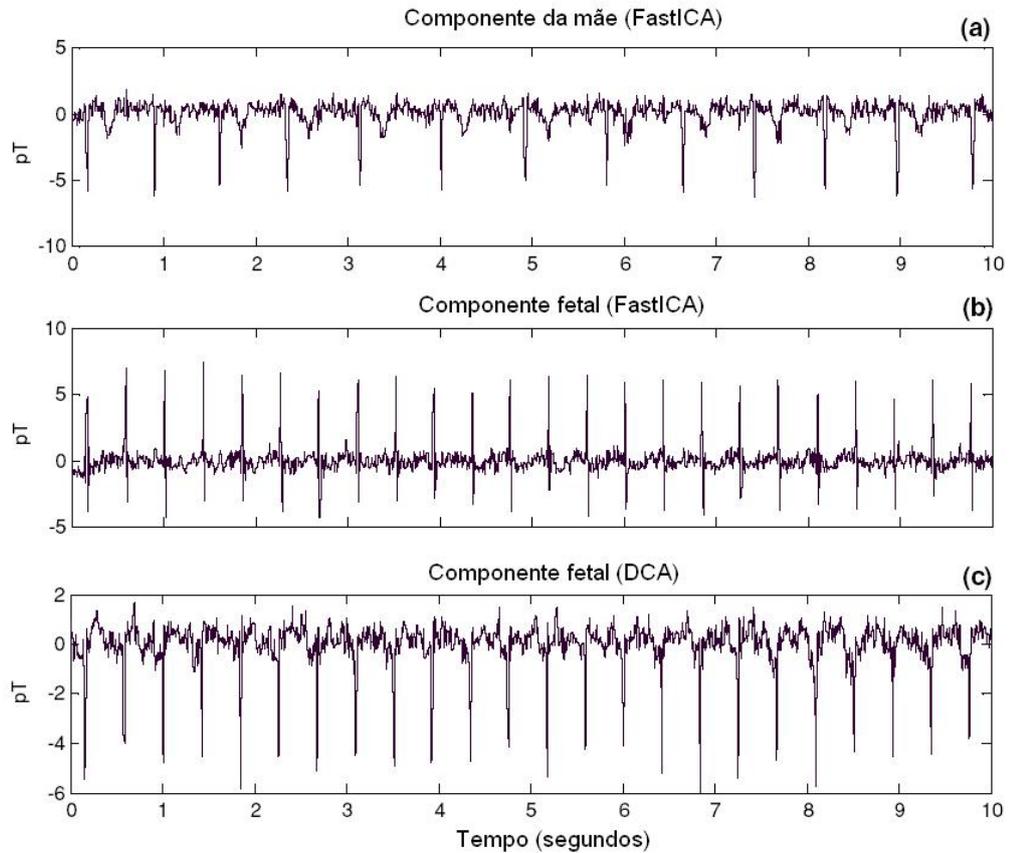
Figura 9 observa-se que os batimentos cardíacos do feto têm uma frequência maior que os batimentos da mãe, ainda, a amplitude do MCG da mãe é maior que o MCG fetal.



**Figura 9 :** Espectro de potência de um registro simples. Dois picos correspondentes à componente fetal e à componente da mãe são observados.

Após encontrar um pólo em 1,5 Hz, sinal consistente com uma taxa de batimento cardíaco no adulto, e um outro em 2,4 Hz, consistente com uma taxa de batimento cardíaco fetal, foi aplicado o algoritmo de ACD conforme descrito no capítulo anterior. A Figura 10(c) mostra o sinal cardíaco fetal extraído pelo método de ACD, onde o MCGf é claramente preservado e a interferência materna é removida.

Para comparar o resultado do algoritmo proposto com o resultado obtido pelo método de FastICA, o método FastICA foi aplicado ao mesmo conjunto de dados, resultando na Figura 10(a) e Figura 10(b). De forma geral, o método FastICA utiliza varias etapas durante o processo, os quais são evitados quando utilizado o algoritmo proposto. Assim, enquanto no FastICA é necessário encontrar a melhor combinação de sinais de entrada, para formar agrupamentos específicos e obter um resultado estável, no algoritmo proposto .....?????



**Figura 10** : Componentes separadas do MCG da mãe (a) e do MCG fetal (b), obtidas por fastICA, e MCG fetal (c) extraído por ACD baseado na análise espectral auto-regressiva. Esta última é considerada um sinal mais consistente com os batimentos cardiacos fetais. Basicamente, a diferença entre (b) e (c) é o método utilizado, tendo cada um seu próprio forma para aproximar a componente fetal.

---

## **CAPÍTULO 5. COMPONENTES GASTRICOS A PARTIR DE MAGNETOGASTROGRAMAS**

Capítulo que descreve uma aplicação do método de ACD para a detecção das duas componentes da atividade elétrica gástrica após uma refeição, do ritmo elétrico de base (REB) e da atividade de resposta elétrica (ARE). Conforme mencionado no Capítulo 2, os sinais de MGG são altamente contaminados pela respiração, movimento e artefatos cardíacos, além de considerar a possibilidade de interferência pela atividade mioelétrica originada por órgãos, o que pode confundir a interpretação e a análise do MGG (**Liang et al. 2000**). Em particular, a detecção da ARE é difícil devido a apresentar um baixo nível de amplitude, possuindo sobreposição espectral com os sinais cardíacos, impossibilitando o uso dos métodos de análise existentes, considerados como padrão.

O método de ACD é aplicado para separar os sinais REB e ARE de outras fontes de interferência, mesmo em casos com baixas taxas da relação sinal-ruído. Da mesma forma,, é utilizada uma representação tempo-frequência (RTF) das componentes extraídas, baseada em *wavelets* para examinar as características temporais da REB e da ARE.

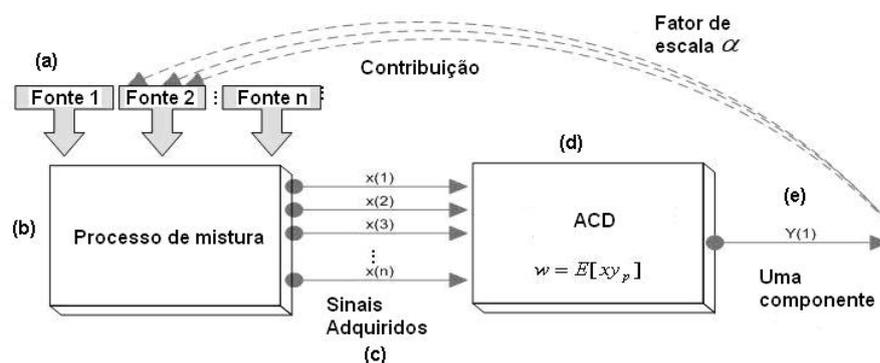
### **5.1. MATERIAL E MÉTODOS**

Os registros foram realizados em um sistema de gradiômetros de primeira ordem (*Magnes, Biomagnetic Technologies, Inc*), sendo colocados no interior de uma sala blindada contra campos magnéticos de alta intensidade. A aquisição de dados realizada na Universidade de Winsconsin-Madison, UW, Estados Unidos, pelo Prof. O. Baffa da Universidade de São Paulo e pelo grupo de pesquisa liderado por o Prof. Ronal Wakai da Universidade de?????. O sistema conformado por duas unidades de magnetômetros, A e B, cada uma contendo 37 canais uniformemente distribuídos sobre áreas circulares, com diâmetros de 13,7 cm e 14,4 cm, respectivamente. Sendo o ruído intrínseco por canal de  $5-10 \text{ fT (Hz)}^{-1/2}$ .

Participaram do estudo, sete voluntários assintomáticos, cada um deles em posição decúbito dorsal sobre uma cama especial. Sendo o magnetômetro A. posicionado sobre seu estômago e, o magnetômetro B posicionado sobre suas costas, ficando ambos alinhados (Estombelo-Montesco et al. 2007a). Com esta disposição experimental foi possível adquirir simultaneamente os sinais das partes anterior e, posterior do estômago; assim como, adquirir sinais do estômago com a menor distância possível.

Três registros de sinais com 10 minutos de duração foram adquiridos. O primeiro registro pré-prandial, antes da ingestão do alimento teste. Seguidamente, um alimento teste (um sanduíche de pão com queijo de 250 kcal) foi oferecido aos sujeitos antes da segunda medida (primer registro pós-prandial). Finalmente, o segundo registro pós-prandial foi adquirido durante o registro de sinais com mais de 10 minutos de duração .

Os sinais de MGG foram amostrados a 73,1 Hz e armazenados para subsequente análise. Os dados digitalizados foram decimados a 4 Hz para eliminar artefatos de altas frequências e interferências, resultando um sinal com largura de banda de pouco menos de 1 ciclo/min. Através do método ‘*decimate*’ do MatLab foi possível reamostrar e realizar a filtragem do sinal.

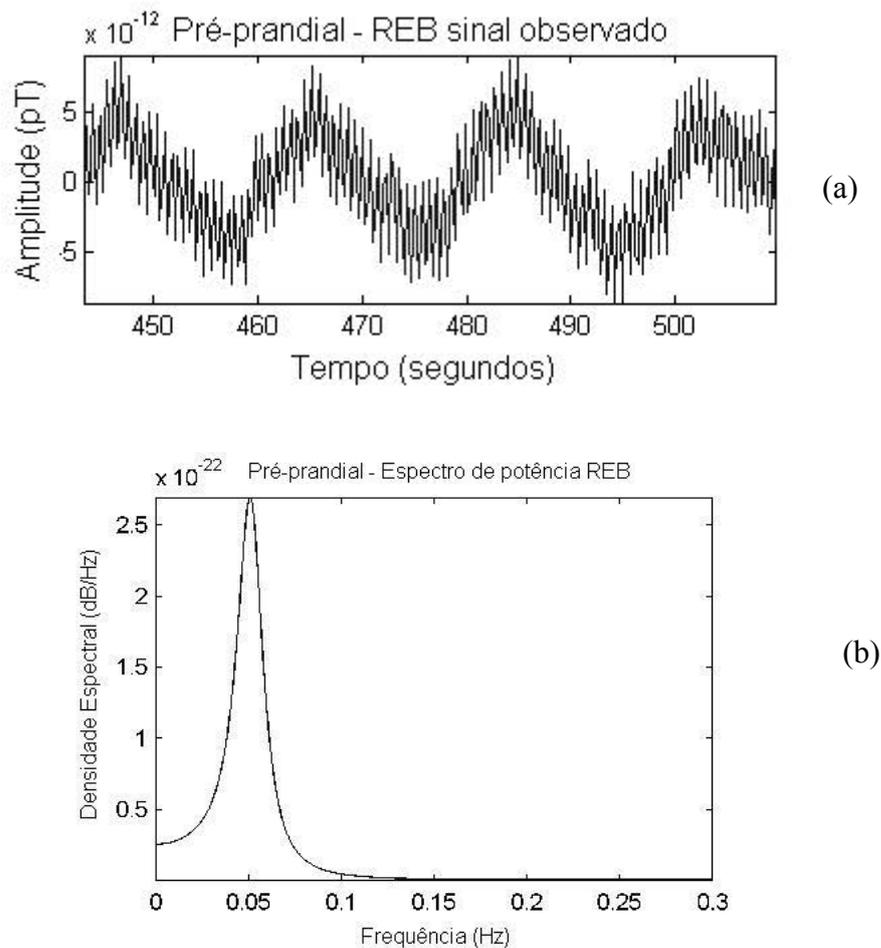


**Figura 11** : Diagrama ilustrativo do método aplicado. (a) Cada fonte (estômago, coração, tecido, artefatos, etc) produz um sinal magnético, não observado diretamente na prática. (b) Os sinais de cada fonte são misturados (linearmente, por hipótese) com os sinais das outras fontes e, a mistura é representada pelo bloco denominado “processo de mistura”. (c) Os sinais adquiridos por cada canal do magnetômetro são, na verdade, misturas dos sinais originais. (d) Após a aquisição dos sinais misturados foi realizada a separação/extração da fonte de interesse através do processo de ACD. (e) Finalmente, na saída há uma única série temporal determinada a menos de um fator de escala, que precisa ser calculada para estimar sua amplitude relativa. Estes passos foram aplicados para os três registros medidos, o pré-prandial e as duas pós-prandiais, respectivamente.

O diagrama da Figura 11 ilustra a estratégia utilizada para a extração das componentes REB e ARE, segundo o método de ACD. Lembramos, que o método ACD depende da estimação *a priori* do atraso temporal, o que é favorável para cada sinal (REB e ARE) e resultante da função de autocorrelação dos sinais, cujas séries temporais são modeladas por AR.

A Figura 12 (b) mostra o espectro de potência representativo dos segmentos do sinal registrado (observado e sem processar), representado pelo pré-prandial da Figura 12 (a). A partir do modelo AR pode-se estimar um atraso temporal apropriado ao sinal de interesse .

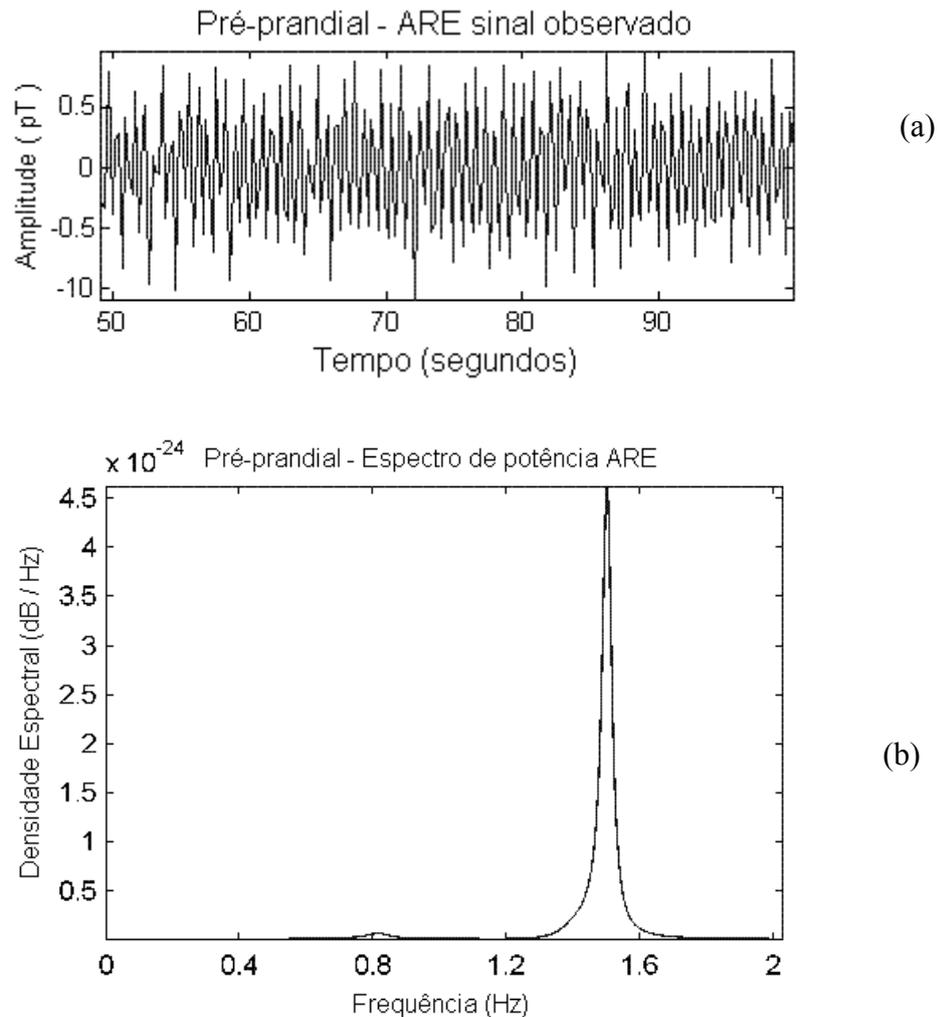
A Figura 12 mostra o espectro de potência do sinal do REB sendo o pico 0,05 Hz (ou 3 cpm). No método ACD esta é a informação *a priori* usada para estimar o atraso temporal..



**Figura 12** : O painel superior mostra o sinal original correspondente ao REB observado após a decimação, sem

nenhum tipo de processamento. O painel inferior mostra o espectro de potência do sinal do painel superior, indicando claramente o sinal REB em 0,05 Hz (3 cpm.).

O espectro de potência dos sinais do coração e da ARE,,através de um único registro pré-prandial, observa-se na Figura 13 (b) e, o registro temporal na Figura 13 (a). Onde a componente do coração (1,5 Hz) é muito mais forte que a componente da ARE (0,8 Hz).

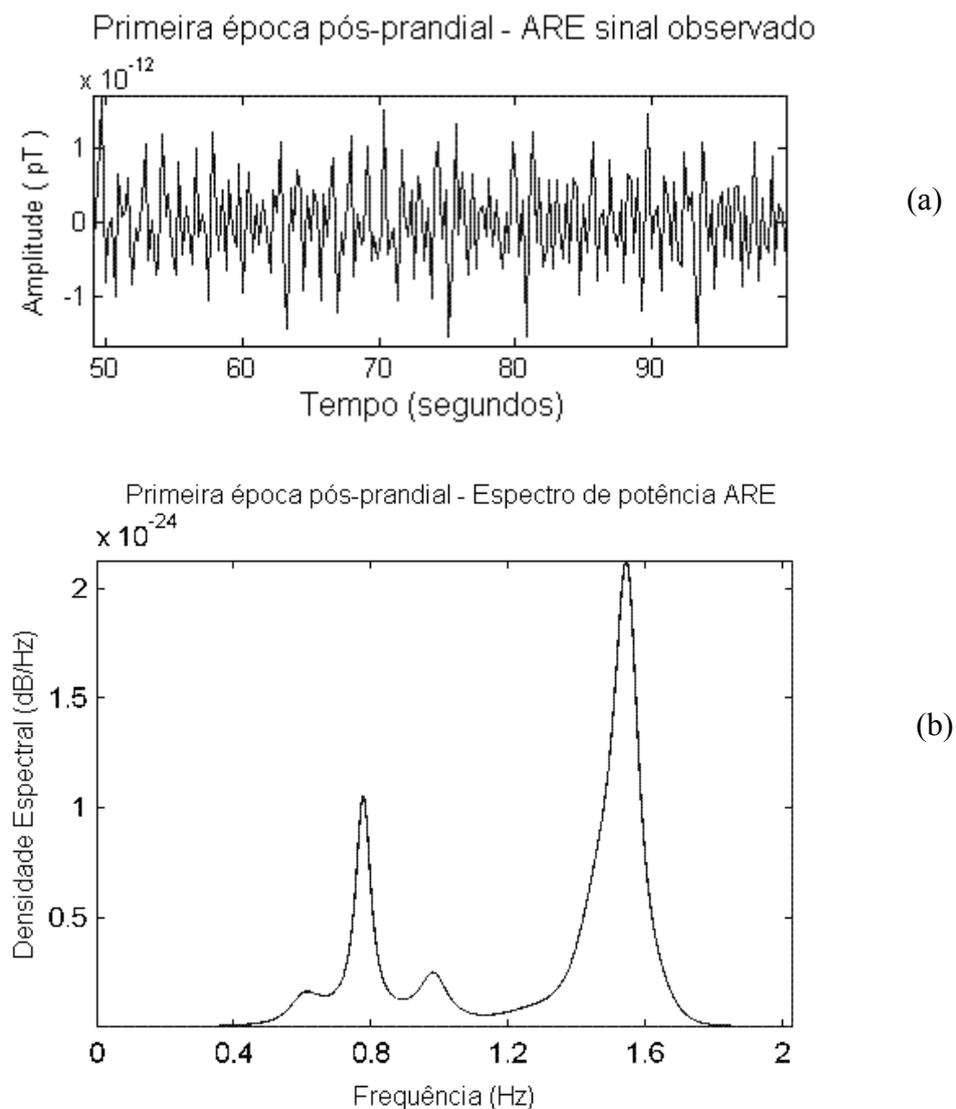


**Figura 13 :** O painel superior mostra a serie temporal original do registro pre-prandial após decimação e, filtragem das frequencias baixas. O painel inferior mostra o espectro de potencia da AER dos registros no pre-prandial, mostrados no painel acima. O sinal AER apresenta energia fraca quando comparado à componente do coração nas altas frequencias.

Comparando-se com o espectro de potência do primeiro registro pós-prandial, mostrado na Figura 14(b), este último mostra uma diferença significativa, cerca de 0,8 Hz, indicando um estado diferente em relação ao caso do registro pré-prandial da Figura 13. Da

mesma forma, a potência associada à ARE no registro pós-prandial é maior que o registro pré-prandial, para a mesma frequência.

A estimação do sinal extraído pela ACD pode ter uma escala diferente ao sinal original, situação que pode levar a comparações errôneas, entre as energias dos registros pré-prandial e pós-prandial. Portanto, a determinação de um fator de escala apropriado é fundamental quando realizada a estimação do sinal. Assim, o fator de escala é determinado pela Equação (23).



**Figura 14** : O painel superior mostra o sinal original do primeiro registro pós-prandial, após decimação e filtragem das frequências baixas (abaixo de 0,35Hz). O painel inferior mostra o espectro de potência deste sinal, com forte pico, aproximadamente de 1,5 Hz, associado ao ritmo cardíaco e, o pico da ARE bastante intenso quando comparado com o pré-prandial, 0,8Hz respectivamente.

O fator de escala fornece duas informações valiosas. A primeira diz respeito a obtenção do fator de escala da componente extraída pela ACD, quando considerado o maior valor absoluto de  $\alpha$ . Assim, quando executado o procedimento, para cada um dos registros, teremos seus respectivos fatores de escala. Desta forma, podem ser comparadas as amplitudes relativas, e analisadas, no domínio da frequência ou no domínio do tempo, e assim, detectar o sinal da ARE, quanto a intensidade e, localização no domínio da frequência.

A segunda informação relacionada a todos os valores inclusos no vetor  $\alpha$ , considerando que cada componente deste vetor pertence a um sensor (ou canal), os quais permitem uma representação espacial e, fornecem suas contribuição desde cada um dos sinais para o sinal fonte. Esse mapa espacial, do sinal fonte estimado, montado a partir do sinal de 37 canais, será mostrado na seção seguinte.

A caracterização dos sinais do REB e da ARE foram realizada por RTF em termos de *wavelets*, sendo a utilizada em este estudo a *wavelet* de Morlet, a qual foi anteriormente definida e descrita. Para o caso específico da MGG, os valores dos parâmetros da *wavelet* de Morlet dados pela Equação (29), utilizados na RTF do sinal do REB, encontram-se na Tabela 2 e, os valores dos parâmetros utilizados para a RTF, da ARE, na Tabela 3.

$\tilde{w}$	$f_0$	$2\sigma_t$ (seg)	$2\sigma_f$ (Hz)
10	0,05	63,66	0,010
7	0,05	44,56	0,014
2	0,05	12,73	0,050
3,5	0,02	55,7	0,011
3,5	0,05	22,3	0,029
3,5	0,09	12,4	0,051

**Tabela 2:** No caso do REB (3 cpm), a tabela mostra o efeito de  $\tilde{w}$  na *wavelet* de Morlet para diferentes frequências  $f_0$ . Neste estudo, o parâmetro foi configurado utilizando o valor de  $\tilde{w} = 3,5$ .

$\tilde{w}$	$f_0$	$2\sigma_t$ (seg)	$2\sigma_f$ (Hz)
16	0,6	8,49	0,08
16	0,8	6,37	0,10
16	1,0	5,09	0,13
21	0,6	11,14	0,06
21	0,8	8,36	0,08
21	1,0	6,68	0,10
26	0,6	13,79	0,05
26	0,8	10,35	0,06
26	1,0	8,28	0,08

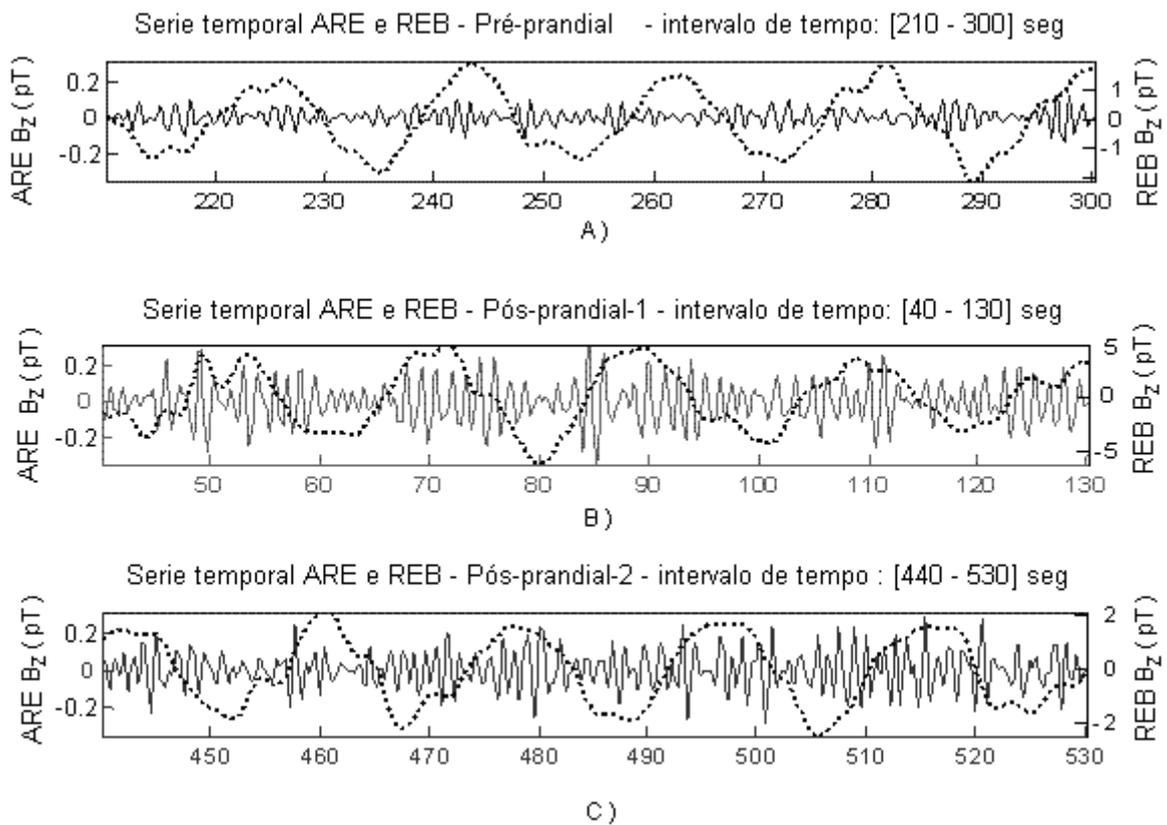
**Tabela 3 :** No caso da ARE, a tabela mostra várias configurações de valores de  $\tilde{w}$  e  $f_0$  para a *wavelet* de Morlet. Sendo o parâmetro configurado utilizando o valor de  $\tilde{w} = 21$ .

## 5.2. RESULTADOS

A Figura 15 mostra os três registros, um em cada painel, com as componentes do sinal gástrico associadas ao REB e à ARE extraídas pela ACD. Usualmente para o domínio temporal, a componente do REB possui maior amplitude que a componente da ARE. Assim, para melhor visualização é conveniente mostrar as duas componentes, REB e ARE, cada uma superposta em sua própria escala.

A Figura 15(b) e (c) mostram que a componente da ARE é sempre encontrada no estômago. Pode-se notar que o sinal da ARE pós-prandial tem maior amplitude que o sinal pré-prandial (Figura 15(a), especialmente durante a fase do platô do REB, aproximadamente em 50 seg., 70 seg., 90 seg. e 110 seg. da Figura 15(b), respectivamente.

A contribuição de energia de cada canal, baseado na equação (23) e no fator de escala da Figura 11, pode ser usada para a construção de mapas de contorno das próprias contribuições. Mapas que mostram uma representação espacial da área na qual o sinal fonte emerge. Assim, a representação dos 37 canais para a componente do REB, dos registros pré-prandial e pós-prandial, é representada na Figura 16.

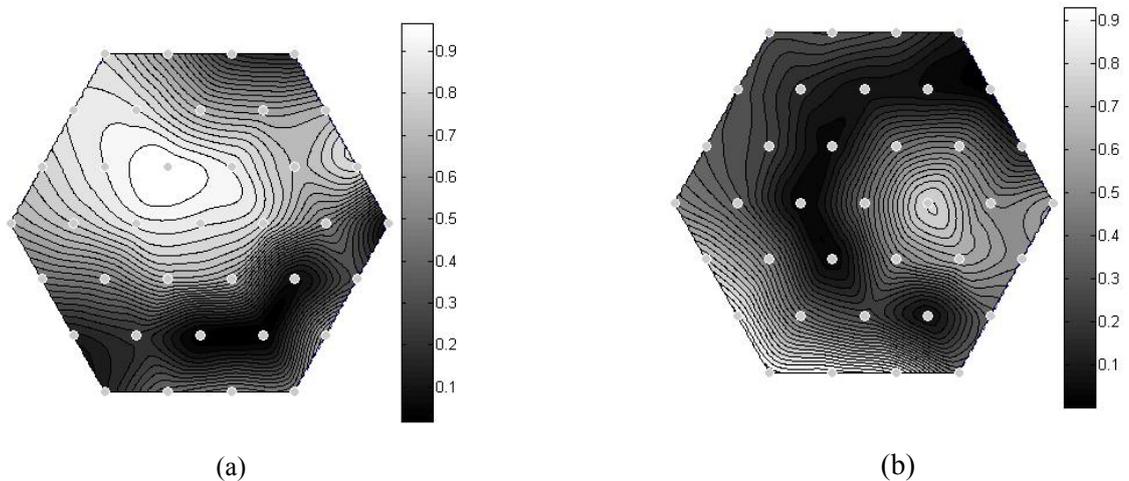


**Figura 15** : Sinais do REB (linha pontilhada) e da ARE (linha sólida) extraídos usando a ACD. (a) componentes extraídas no registro pré-prandial, (b) e (c) componentes extraídas para o primeiro e segundo registro pós-prandial. Do lado direito mostra-se a escala usada para o sinal do REB e, do lado esquerdo, mostra-se a escala usada para o sinal da ARE. O sinal do REB é *um upstroke* seguido por um platô e, pela fase de despolarização lenta com uma frequência aproximada de 3 cpm. Note a diferença de amplitude entre o sinal do REB no registro pré-prandial e o sinal da ARE nos dois registros pós-prandiais. Sendo a escala do eixo  $x$  em segundos.

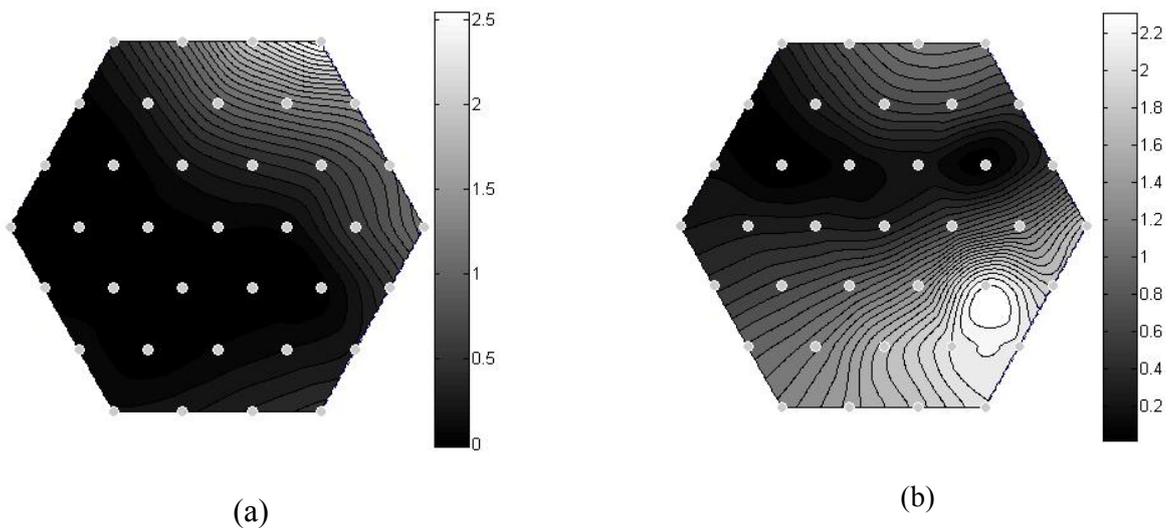
A Figura 17(a) mostra a contribuição de cada canal após a aplicação da ACD para extrair o sinal da ARE no registro pré-prandial. Observa-se uma baixa energia associada ao

ritmo da ARE, observada no canto superior direito, em consequência do sinal cardíaco restante após o processo de extração.

A Figura 17(b) mostra o mapa com as contribuições do sinal da ARE no registro pós-prandial após a extração com ACD. Observa-se um aumento da energia em alguns canais, lado direito do mapa, que apresentavam anteriormente baixas energias (registro pré-prandial).

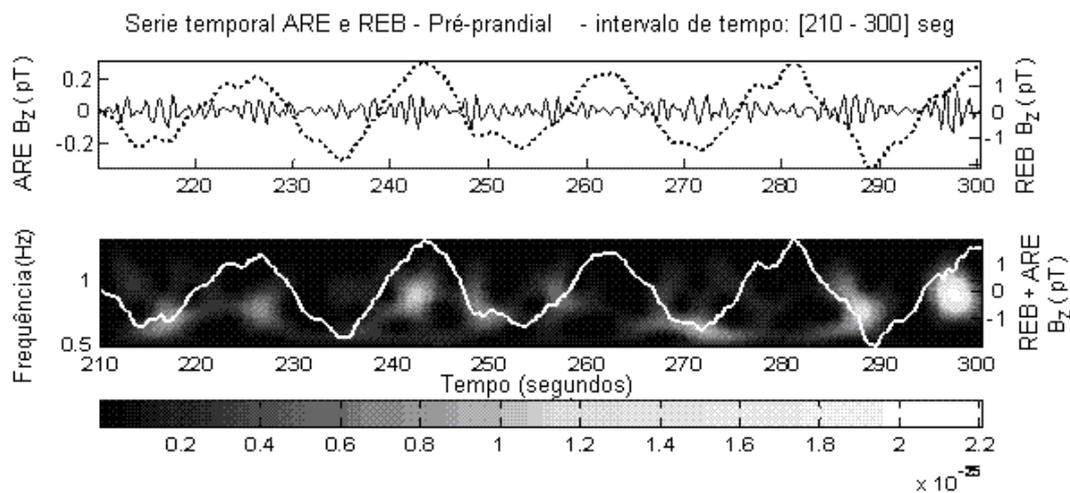


**Figura 16:** Contribuições dos canais para o sinal do REB extraído com ACD. (a) Mapa de contorno do sinal do REB no registro pre-prandial. (b) Mapa de contorno do sinal do REB do registro pós-prandial. Nesses registros, a energia intensa, de onda lenta, se apresenta o tempo todo.



**Figura 17:** Contribuições dos canais para o sinal da ARE extraída com ACD. (a) Mapa de contorno para o sinal da ARE no registro pre-prandial. Nesse registro é esperado que a ARE não apresente contribuição, considerando que no registro pre-prandial não há contrações. (b) Mapa de contorno para o sinal da ARE no primeiro registro pós-prandial, mostrando claramente uma mudança no padrão espacial.

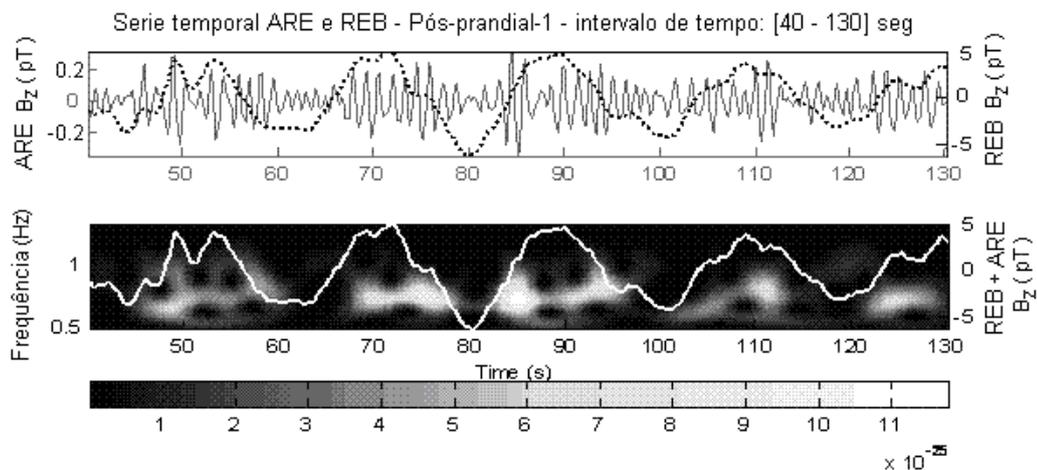
Empregando outra representação, no caso a RTF, e combinando com os resultados obtidos no domínio temporal (Figura 15), obtém-se a Figura 18. Assim, no painel superior, pode-se observar novamente os sinais do REB e da ARE durante o registro pré-prandial. Por outro lado o painel inferior mostra uma linha branca contínua, obtida pela soma das séries temporais do REB e da ARE, sobreposta à representação tempo-freqüência do sinal da ARE, obtida pela transformada de *wavelet*. Para o caso o eixo vertical da RTF encontra-se entre 0,5 Hz e 1,3 Hz, respectivamente. Também foram localizadas algumas regiões de alta energia, porém elas não estão consistentemente em fase com a componente do REB.



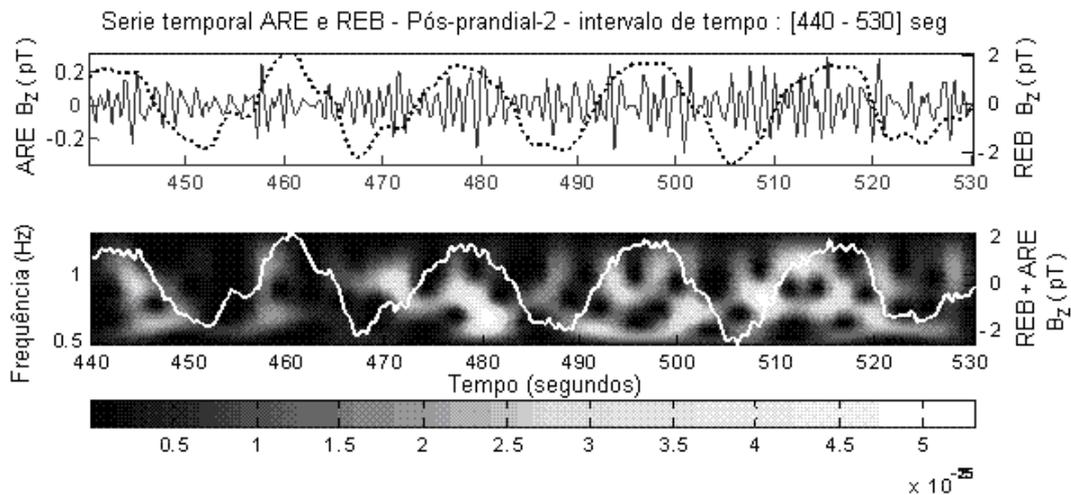
**Figura 18:** Intervalo de tempo durante o registro pré-prandial, com as componentes do REB e da ARE no painel superior e, a RTF da componente da ARE no painel inferior. A linha branca contínua sobreposta à RTF do painel inferior é a soma das componentes do REB e da ARE. A escala do lado esquerdo corresponde à componente da ARE e, a escala do lado direito corresponde à componente do REB.

Na Figura 19, no painel superior, mostram-se os sinais do REB e da ARE durante o primeiro registro pós-prandial, onde a amplitude do sinal da ARE é maior, neste caso, que o registro pré-prandial. Nota-se na RTF do painel inferior pontos de alta energia da componente da ARE, que estão em fase com a componente do REB, característica de importância para ratificar a existência da componente da ARE. Uma outra característica que deve ser observada é a freqüência da componente da ARE, a qual embora esteja concentrada em 0,8 Hz, pode variar no tempo aumentando até 1,30 Hz, mas, ao mesmo tempo pode se manter em fase com a componente do REB no platô.

Na Figura 20, no painel superior, mostram-se os sinais do REB e da ARE durante o segundo registro pós-prandial. Pode-se observar que a amplitude do sinal da ARE continua alta, como no primeiro registro pós-prandial. No painel inferior, da mesma Figura, a RTF da componente da ARE tem uma distribuição de energia mais difusa que no registro anterior. No entanto, ela ainda se mantém em fase com o sinal do REB, apesar da diminuição de energia.



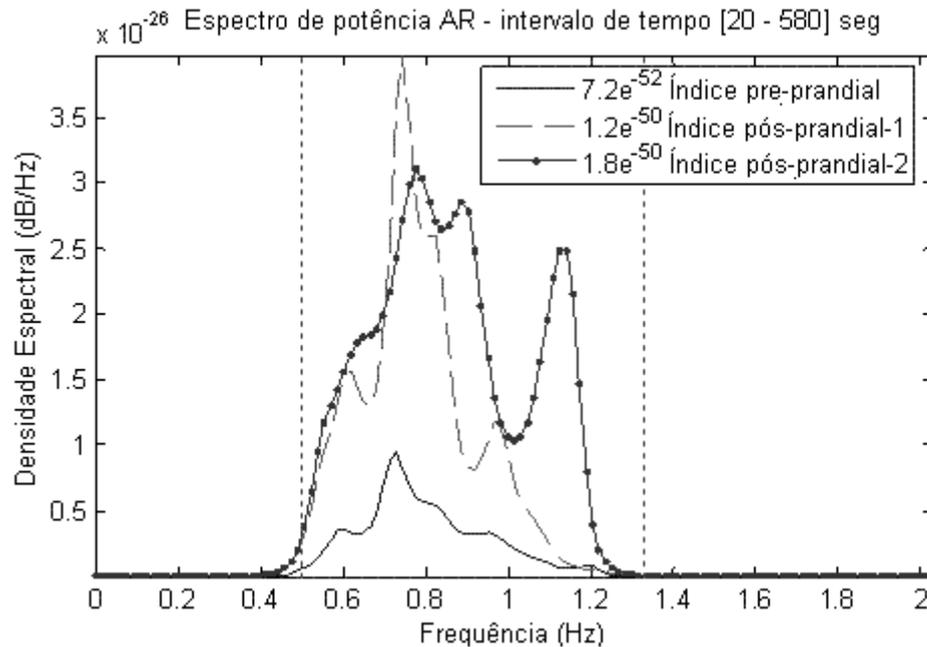
**Figura 19:** Intervalo de tempo durante o primeiro registro pós-prandial mostrando as componentes do REB e da ARE. Pode-se observar os potenciais de ação associados à componente da ARE no painel superior, correspondentes com os pontos luminosos na RTF do painel inferior, em fase com a componente do REB. A frequência da componente da ARE na RTF varia de 0,6 Hz. a 1,0 Hz. As escalas desta figura são similares às da **Figura** .



**Figura 20:** Intervalo de tempo durante o segundo registro pós-prandial mostrando as componentes do REB e da ARE. Note-se que o sinal da ARE está mais distribuído, quanto o tempo e a frequência, embora mantenha-se em fase com a componente do REB.

Após a extração dos sinais desejados pelo método de ACD e ser estimado o fator de escala, pode-se calcular o espectro de potência para determinar a energia da componente da ARE, em cada registro, usando-se o método AR. Os resultados (Figura 21) mostram um aumento na amplitude do sinal na faixa de 0,6 Hz a 1,0 Hz. A frequência dominante nesta faixa é de 0,8 Hz, em geral, correlacionada com a maior intensidade do REB. O centro da banda da frequência e sua largura variam de um sujeito para outro, portanto é de importância a aquisição do sinal pré-prandial, como controle.

Para sintetizar essas diferenças encontradas no espectro de potência auto-regressivo e, permitir comparações entre elas é necessário gerar uma variável, designada como índice, para representar cada espectro de potência em cada componente da ARE. Índice que é gerado integrando a área inferior da curva do espectro de potência, localizado entre as frequências 0,5 Hz e 1,33 Hz. Os valores do índice para cada curva são mostrados na inserção da Figura 21.



**Figura 21:** Espectro de potência auto-regressivo da componente da ARE durante o registro pré-prandial e, os dois registros pós-prandiais de um sujeito, após sua extração pelo método da ACD. A inserção mostra o índice calculado para cada registro.

Os sinais adquiridos para os 7 sujeitos (Tabela 4) mostram um aumento nos índices dos registros pós-prandiais quando comparados com os registros pré-prandiais. As variações observadas no índice, entre os registros pré- e pós-prandial, e nos indivíduos podem ser devidas ao tônus muscular do estômago, à forma do corpo e, a camada de gordura, entre as principais.

**Tabela 4 :** Índice para cada registro (entre 0,5 Hz e 1,33 Hz)  $\times 10^{51}$ .

	Pré-prandial	Pós-prandial (1)	Pós-prandial (2)
Voluntário – 1	8.0	1100	930
Voluntário – 2	0.72	12	18
Voluntário – 3	9.0	91	120
Voluntário – 4	27	29	44
Voluntário – 5	16	300	83
Voluntário – 6	4.2	2800	5100
Voluntário – 7	8.6	99	180

## **CAPÍTULO 6. COMPONENTE AUDITIVO A PARTIR DE DADOS DE FMRI**

Trabalhos recentes sugerem que o potencial dos métodos de separação cega de fontes, como a ACI, para o análise de dados de fMRI vão em aumento, especialmente quanto informação *a priori*, quanto a disponibilidade, é quando incorporada à estimativa das componentes (**Suzuki et al. 2002**).

Esses trabalhos encorajaram a proposta do uso da ACD para analisar dados em fMRI. Nas aplicações supracitadas, baseadas na ACI, foram utilizadas informação sobre o protocolo experimental adotado, embora, no caso da ACD, esta informação esteja contida no próprio conjunto de dados. Da mesma forma, a abordagem de ACD proposta para fMRI mantêm a idéia de extrair apenas a componente de interesse, baseada na estrutura dos próprios dados. Característica considerada um avanço em relação a trabalhos anteriores (**Calhoun et al. 2005**), pois deixa-se de precisar de informação *a priori* sobre o paradigma experimental e, passa-se a precisar apenas de informação contida no próprio conjunto de dados.

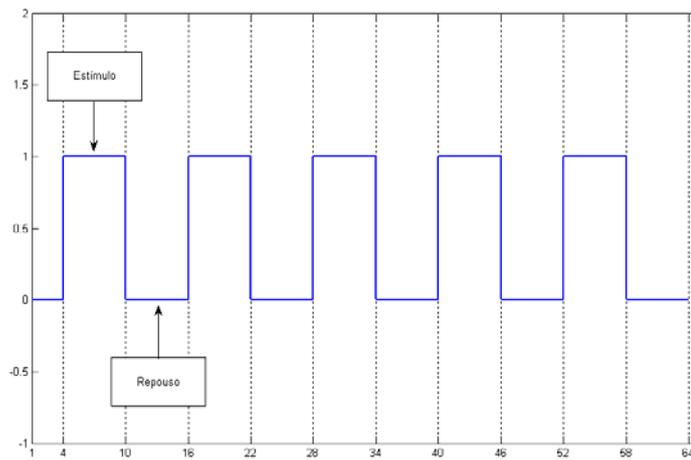
### **6.1. MATERIAL E MÉTODOS**

O maior problema encontrado refere-se à determinação de fonte de estímulo auditivo a partir de medidas de fMRI. O paradigma experimental foi baseado na escuta passiva de uma história complexa, com estrutura narrativa padrão. Cada experimento composto por seis blocos de controle de 27,5 s, onde o indivíduo permanecia em repouso, sendo alternados com cinco blocos durante os quais o indivíduo recebia o estímulo.

Os dados de fMRI foram adquiridos com um scanner (*Siemens 1.5 T, Magnetom vision scanner*) pelos integrantes do grupo de pesquisa no Hospital das Clínicas de Ribeirão Preto em colaboração com o Laboratório NeuroImago, do Departamento de Física e Matemática da Faculdade de Filosofia ciências e Letras de Ribeirão Preto - USP. As medidas

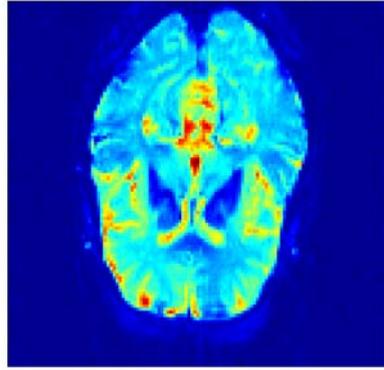
foram executadas em uma sessão contendo 64 volumes de 16 fatias cada, usando seqüências rápidas de pulsos de tipo eco-planar (EPI). Da mesma forma, imagens de alta resolução espacial foram adquiridas para sobrepor os mapas funcionais, obtidos no final do processamento,.

O protocolo utilizado pode ser observado na Figura 22. O eixo horizontal, graduado em termos de número de pontos, mostra a duração de cada bloco, tanto em repouso como em estímulo. Deve-se observar que o primeiro bloco (repouso) tem uma duração menor, pois seus pontos fazem parte do período no qual o equipamento foi calibrado.



**Figura 22:** Esquema do protocolo em blocos usado durante o experimento. Os 64 pontos do eixo horizontal são equivalentes a 289,8 segundos. Os primeiros 12,7 s foram utilizados para calibração do aparelho.

Na Figura 23 se observa uma amostra dos dados observados, sem a aplicação de qualquer processo de extração. De forma específica, a imagem tem 128x128 pixels, e pertence à fatia 12 do total de 16 fatias, correspondente ao instante do ponto 32.



**Figura 23** : Exemplo de medida de fMRI sem processamento de extração. Matriz original de 128x128 pixels, fatia 12, amostragem 32 de 64 pontos.

Considerando que o mecanismo de contraste BOLD aliado às técnicas de aquisição rápida permite a visualização direta de um grande número de processos cerebrais, procurando séries temporais, resultantes de etapas de pré-processamento, que favoreçam a eliminação de alguns artefatos conhecidos, antes de ser analisadas com ferramentas estatísticas ou algoritmos de extração. Os seguintes tipos de pré-processamento foram realizados baseados em dados: pré-processamento para a correção temporal entre fatias; pré-processamento para a correção de movimento; e pré-processamento para a redução na dimensão dos dados.

A avaliação do desempenho é importante para coeherer a eficácia do método, sendo a maioria das vezes realizado por comparação com outros métodos, considerados padrões. Entretanto, diante da dificuldade de obter um teste padrão para a fMRI, é comum estudar seu desempenho por meio de dados simulados (**Sturzbecher 2006**).

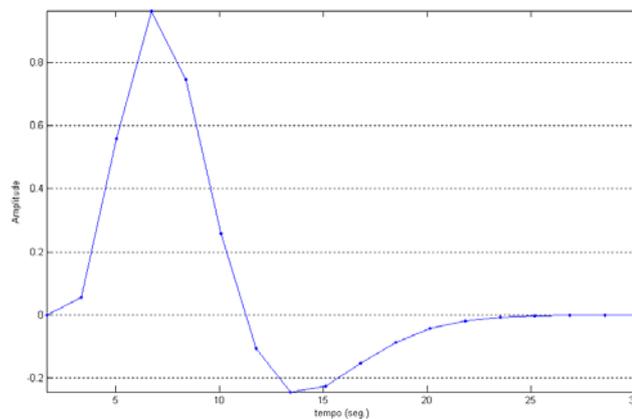
Assim, neste estudo foram gerados, artificialmente, conjuntos de dados em 3-D, de 64x64 voxels com séries temporais da função de resposta hemodinâmica (FRH). Utilizando para tal finalidade uma equação de modelação analítica (**Glover 1999**):

$$h(t) = \left(\frac{t}{d}\right)^a \exp\left(-\frac{t-d}{b}\right) - c \left(\frac{t}{d'}\right)^{a'} \exp\left(-\frac{t-d'}{b'}\right).$$

Neste modelo,  $d = ab$  é o momento do pico da FRH e  $d' = a'b'$  é o momento do *undershoot* da FRH. Sendo os parâmetros utilizados:  $a = 6$ ,  $a' = 12$ ,  $b = b' = 0,9$  e  $c = 0,35$ .

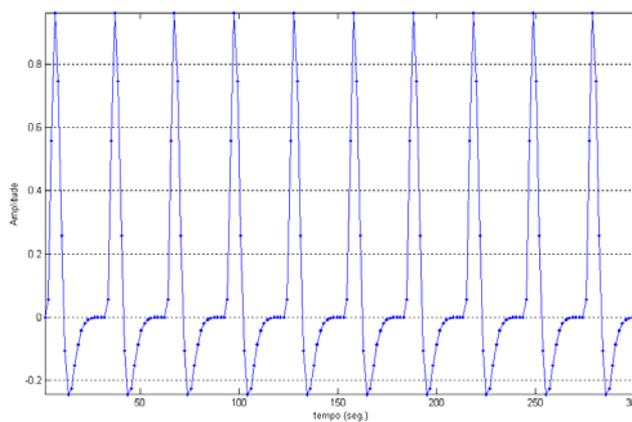
Assim, na Figura 24 se observa o comportamento da função para estes parâmetros.

Nas colunas de 1 a 32 encontram-se os voxels com padrão de ativação, ou seja, contendo um sinal BOLD, enquanto nas colunas de 32 a 64 observa-se o ruído, modelado por um padrão gaussiano uniforme.



**Figura 24 :** Modelo da função hemodinâmica utilizada nos dados simulados.

Na Figura 25 se observa uma série temporal baseada no modelo da FRH anteriormente mostrada.



**Figura 25 :** Série temporal de funções de resposta hemodinâmicas baseadas no modelo da **Figura 24** .

Antes de processar os dados de fMRI com as 16 fatias, é interessante realizar a análise da fatia que contém a maior quantidade de atividade neural. Nesse sentido, não conhecendo a fatia com maior quantidade de ativação neural, devido ao experimento auditivo, deverá ser,

empiricamente, escolhida a melhor fatia. Uma das formas mais simples é realizar uma correlação cruzada, artificial, de cada fatia com um sinal variável no tempo, formada por impulsos de tipo ativado-desativado, como se dá no protocolo experimental.

Este teste empírico permitiu inferir que a fatia 12 poderia conter a maior intensidade do sinal procurado. A partir deste ponto foi possível aplicar o método de ACD, pois ele pode ter um melhor desempenho quando utilizados os dados da fatia 12.

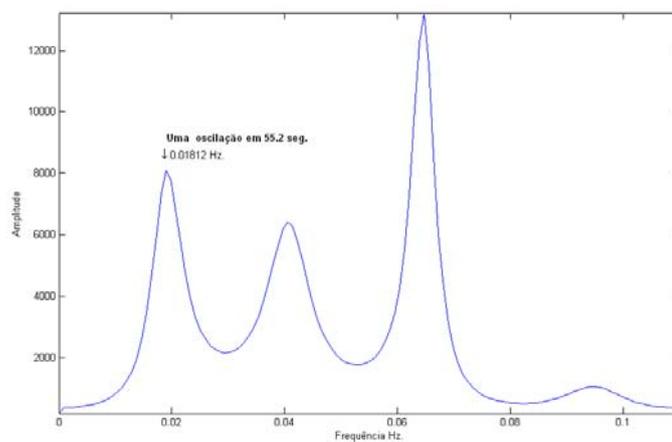
Uma outra questão foi a quantidade de séries temporais processadas. Considerando que cada fatia é composta por 128x128 pixels e, que cada pixel gera uma série temporal, assim temos que a quantidade de dados é enorme. No caso deste experimento a resolução espacial foi boa, 128x128 pixels respectivamente; em contraste com a resolução temporal que foi menor (64 pontos de referência amostrados), porém suficiente para que a função de resposta hemodinâmica seja reconhecida.

Por outro lado, precisavamos de trabalhar apenas com os pixels que sejam relevantes ou, pelo menos, com aqueles que estejam na área do cérebro. Para tal fim, foi aplicado uma máscara sobre a fatia selecionada, a qual detectou a região do cérebro que contém os pixels. Assim, somente as séries temporais desses pixels foram utilizadas no processo de extração.

Após os diferentes tipos de pré-processamento, descritos acima, foi necessário identificar, com base na informação intrínseca dos dados, a informação *a priori* necessária para a determinação do atraso temporal, a ser usado na modelagem AR. Isto é feito a partir do cálculo do espectro de potência do sinal, resultado representativo, mostrado na Figura 26. Nesta figura observa-se claramente a componente, em 0,018 Hz, relacionada com o experimento. Para verificação, o mesmo foi comparado com a frequência resultante de uma oscilação ( $2 \times 27,5 \text{ s} = 55 \text{ seg}$ ), que é igual a 0.01818 Hz.

Uma vez identificada a informação *a priori*, o próximo passo foi realizar uma redução na dimensão (branqueamento) dos dados, para trabalhar com os dados mais significativos.

O procedimento de extração propriamente dito é feito para cada fatia, ou seja, uma a uma. A matriz original de 3 dimensões, <pixel X, pixel Y, ponto amostrado no tempo>, foi transformada em uma matriz bidimensional, com número de pixels por número de pontos amostrados: <16384, 64>. Esta última matriz é a entrada para o método de ACD, deve observar-se que existe uma relação- quando mapeada cada posição do pixel (vetor linha) da matriz, em sua posição na matriz original- que é usada para posterior localização e criação do mapa de ativação.

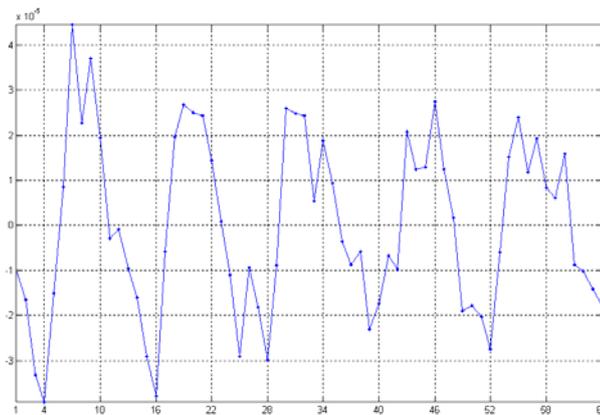


**Figura 26 :** Espectro de potência AR de uma série temporal pertencente a um voxel. Observa-se a existência da componente em torno de 0,018 Hz.

## 6.2. RESULTADOS

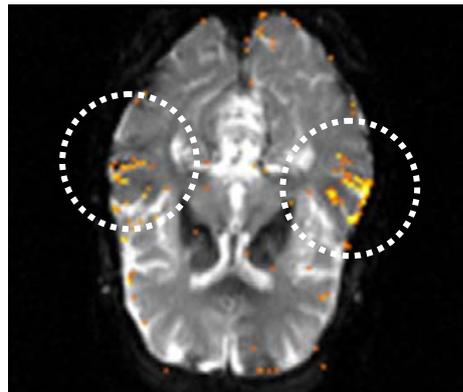
A Figura 27 mostra os dados de fMRI, após ser processados com a ACD, a saída é a componente da fonte auditiva, existindo uma forte correlação com o protocolo e, o paradigma usado no domínio do tempo, da Figura 22.

Em consequência, a componente da Figura 27 foi correlacionada com as séries temporais das imagens, obtendo-se como resultado os mapas de ativação, os quais foram sobrepostos às imagens, utilizando-se o software de visualização MRIcro. As ativações detectadas foram localizadas na área do córtex, correlacionada com o experimento auditivo deste trabalho, observado na Figura 28.



**Figura 27** : Componente auditiva extraída. Para um sinal quase-periodico, a ACD identifica a componente baseada no atraso temporal determinado a partir das caraterísticas temporais da resposta hemodinâmica auditiva.

---



**Figura 28** : Área de atividade detectada no experimento de fMRI auditivo (fatia 12 do total de 16 fatias). Mapa de localização da atividade obtido por correlação cruzada entre a componente extraída (representando a função de resposta hemodinâmica auditiva) e o conjunto de dados originais (observações), obtidos por fMRI.

---

## CAPÍTULO 7. DISCUSSÃO E CONCLUSÕES

Os resultados obtidos mostram: a) a extração da componente fetal a partir de magnetocardiogramas, resultados que além do baixo custo, são alentadores quando comparados com o método FasICA da literatura. As etapas de pré-processamento são simples, sendo de importância o cálculo do atraso do sinal a ser extraído, para a posterior extração da componente através do ACD.

Outros resultados estão diretamente relacionados com os registros de Magnetogastrografia, especificamente, a detecção, a caracterização da atividade de resposta elétrica (ARE) e o ritmo elétrico de base (REB). A aplicação neste estudo, obteve resultados não reportados na literatura.

Nesse sentido, os resultados obtidos acompanham uma série de representações em Tempo-Frequência, das componentes ARE, para validar a componente achada, indicando que encontram-se, no platô, em fase com a componente REB. Medidas realizadas, com outros voluntários, foram analisadas, confirmando o aumento da atividade elétrica após a refeição com o alimento teste.

Os resultados da terceira aplicação, com fMRI, foram corroborados pela literatura. Nesta aplicação o número de sinais a serem analisados aumentou significativamente, sendo que cada pixel representava uma série temporal com uma imagem que variava ao longo do tempo. Assim, cada componente desejada estava relacionada com o experimento de tipo auditivo e, sua extração indicou a existência de atividade cerebral nas áreas laterais do cérebro. Esta abordagem utiliza a ideia de estrutura de correlação, entre as componentes, assim é considerada uma abordagem de maior interesse que aquela por correlação entre a fonte e o protocolo utilizado.

Na maioria dos casos, a extração de todas as fontes foi desnecessária. A formulação deste método designado por ACD levou a uma simples regra de aprendizagem que permite a obtenção de resultados comparáveis com as melhores técnicas de uso na área, onde as vezes, a formulação pode ser bastante complexa. De fato, este método não é afetado (não é sensível) pela dimensão dos dados, como no caso de dados fMRI.

A ACD obteve um bom desempenho a) na detecção e extração dos sinais desejados para as diferentes aplicações, MCG fetal e Magnetogastrografia, onde foram usados sinais biomagnéticos (37 canais); e, b) no mapeamento de atividades cerebrais através de fMRI, através de protocolos bem definidos. Resultados que abrem possibilidades para outros tipos de aplicações no processamento de sinais biomédicos, com vários sensores de aquisição no tempo.

O atraso temporal foi uma variável muito utilizada com a componente de interesse, a qual tem um determinado período ou quase-periódico de repetição. Embora, esta condição pode ser relaxada, se encontrada uma referência temporal.

Sendo assim, os resultados das aplicações indicam que o método proposto é eficaz, mostrando seu potencial para futuras aplicações clínicas. A proposta de trabalhos futuros a serem desenvolvidos referem-se à extensão do método para um contexto espaço-temporal, isto é, extrair componentes de interesse com características espaço-temporais.

## Referências

- Akaike, H. 1974, "New Look at Statistical-Model Identification  
2", *Ieee Transactions on Automatic Control*, vol. AC19, no. 6, pp. 716-723.
- Aldroubi, A. & Unser, M. 1996, *Wavelets in medicine and biology* Boca Raton.
- Andrä, W. & Nowak, H. 2006, *Magnetism in Medicine : A Handbook* Wiley-vch.
- Auranen, T. 2002, *Nonparametric statistical analysis of time-frequency representations of magnetoencephalographic data*, HELSINKI UNIVERSITY OF TECHNOLOGY.
- Baffa, O., Wakai, R. T., Sousa, P. L., & Verzola, R. M. M. 1995, "Fetal Heart-Rate Monitoring by Magnetocardiograms  
1", *Brazilian Journal of Medical and Biological Research*, vol. 28, no. 11-12, pp. 1333-1337.
- Barros, A. K. & Cichocki, A. 2001, "Extraction of specific signals with temporal structure", *Neural Computation*, vol. 13, no. 9, pp. 1995-2003.
- Barros, A. K. & Cichocki, A. "Neural Coding by Redundancy Reduction and Correlation", in *the VII Brazilian Symposium on Neural Networks (SBRN'02)*, pp. 223-226.
- Barros, A. K., Cichocki, A., & Ohnishi, N. "Extraction of Statistically Dependent Sources with Temporal Structure", in *VI Brazilian Symposium on Neural Networks (SBRN'2000)*, pp. 61-65.
- Boardman, A., Schindwein, F. S., Rocha, A. P., & Leite, A. 2002, "A study on the optimum order of autoregressive models for heart rate variability  
1", *Physiological Measurement*, vol. 23, no. 2, pp. 325-336.
- Calhoun, V. D., Adali, T., Stevens, M. C., Kiehl, K. A., & Pekar, J. J. 2005, "Semi-blind ICA of fMRI: a method for utilizing hypothesis-derived time courses in a spatial ICA analysis", *Neuroimage*, vol. 25, no. 2, pp. 527-538.
- Carneiro, A. A. O., Ferreira, A., MoMoraes, E. R., de Araujo, D. B., Sosa, M., & Baffa, O. 2000, "Biomagnetismo: Aspectos Instrumentais e Aplicações", *Revista Brasileira de Ensino de Física*, vol. 22, pp. 324-338.
- Cichocki, A., Rutkowski, T., & Siwek, K. "Blind signal extraction of signals with specified frequency band", in *12th IEEE Workshop on Neural Networks for Signal Processing, 2002*, pp. 515-524.
- Comani, S., Mantini, D., Pennesi, P., Lagatta, A., & Cancellieri, G. 2004, "Independent component analysis: fetal signal reconstruction from magnetocardiographic recordings", *Computer Methods and Programs in Biomedicine*, vol. 75, no. 2, pp. 163-177.
- Comon, P. 1994, "Independent Component Analysis, A New Concept", *Signal Processing*, vol. 36, no. 3, pp. 287-314.

- de Araujo, D. B. 2002, *SOBRE NEUROIMAGENS FUNCIONAIS POR MAGNETOENCEFALOGRAFIA E RESSONÂNCIA MAGNÉTICA: NOVOS MÉTODOS E APLICAÇÕES*, DFM.
- de Araujo, D. B., Barros, A. K., Estombelo-Montesco, C., Zhao, H., da Silva, A. C. R., Baffa, O., Wakai, R., & Ohnishi, N. 2005, "Fetal source extraction from magnetocardiographic recordings by dependent component analysis", *Physics in Medicine and Biology*, vol. 50, no. 19, pp. 4457-4464.
- Estombelo-Montesco, C. A., de Araujo, D. B., Silva Filho, A. C. R., Moraes, E. R., Barros, A. K., Wakai, R. T., & Baffa, O. Dependent component analysis for the magnetogastrographic detection of human electrical response activity. *Physiological Measurement* 28, 1-16. 2007a.  
Ref Type: Journal (Full)
- Estombelo-Montesco, C. A., Sturzbecher, M., Barros, A. K., Baffa, O., & de Araujo, D. B. "A new data-driven analysis for functional MRI", in *Workshop on Cerebral Perfusion and Brain Function: Novel Techniques and Applications*, Salvador, Bahia.
- Ferreira, A. J. 2002, *Aplicação da análise em componentes independentes na compressão de imagem*, Engenharia Electrotécnica e de Computadores, Univ. Técnica de Lisboa.
- Glover, G. H. 1999, "Deconvolution of impulse response in event-related BOLD fMRI", *Neuroimage*, vol. 9, no. 4, pp. 416-429.
- Hyvarinen, A. & Oja, E. 1997, "A fast fixed-point algorithm for independent component analysis", *Neural Computation*, vol. 9, no. 7, pp. 1483-1492.
- Hyvarinen, A. & Oja, E. 2000, "Independent component analysis: algorithms and applications 22", *Neural Networks*, vol. 13, no. 4-5, pp. 411-430.
- Irimia, A., Richards, W. O., & Bradshaw, L. A. 2006, "Magnetogastrographic detection of gastric electrical response activity in humans", *Physics in Medicine and Biology*, vol. 51, no. 5, pp. 1347-1360.
- James, C. J. & Hesse, C. W. 2005, "Independent component analysis for biomedical signals 1", *Physiological Measurement*, vol. 26, no. 1, p. R15-R39.
- Kaufman, L., Kramer, D. M., Crooks, L. E., & Ortendahl, D. A. 1989, "Measuring Signal-To-Noise Ratios in Mr Imaging", *Radiology*, vol. 173, no. 1, pp. 265-267.
- Liang, H., Lin, Z., & McCallum, R. W. 2000, "Artifact reduction in electrogastrogram based on empirical mode decomposition method", *Medical & Biological Engineering & Computing*, vol. 38, no. 1, pp. 35-41.
- Madisetti, V. K. & Williams, D. B. 1998, *The digital signal processing handbook*.
- Marple, L. S. 2005, *Digital Spectral Analysis with Applications in C, FORTRAN, and MATLAB* Pearson Higher Education.
- Mintchev, M. P. ELECTRICAL PHENOMENA IN THE HUMAN STOMACH. Department of Electrical and Computer Engineering, University of Calgary, (Canada) . 2007.

2007.

Ref Type: Electronic Citation

- Moraes, E. R., Troncon, L. E. A., Baffa, O., Oba-Kunyoshi, A. S., Wakai, R., & Leuthold, A. 2003, "Adaptive, autoregressive spectral estimation for analysis of electrical signals of gastric origin", *Physiological Measurement*, vol. 24, no. 1, pp. 91-106.
- Rioul, O. & Vetterli, M. Wavelet and signal processing. *IEEE Signal Processing Magazine* 8[4], 14-38. 1991.  
Ref Type: Magazine Article
- Sadowsky, J. 1996, "Investigation of signal characteristics using the continuous wavelet transform", *Johns Hopkins Apl Technical Digest*, vol. 17, no. 3, pp. 258-269.
- Spyers-Ashby, J. M., Bain, P. G., & Roberts, S. J. 1998, "A comparison of fast Fourier transform (FFT) and autoregressive (AR) spectral estimation techniques for the analysis of tremor data 3", *Journal of Neuroscience Methods*, vol. 83, no. 1, pp. 35-43.
- Sturzbecher, M. 2006, *Detecção e caracterização da resposta hemodinâmica pelo desenvolvimento de novos métodos de processamento de Imagens Funcionais por Ressonância Magnética*, Faculdade de Filosofia Ciências e Letras de Ribeirão Preto da Universidade de São Paulo – Área de Concentração: Física Aplicada a Medicina e Biologia.
- Suzuki, K., Kiryu, T., & Nakada, T. 2002, "Fast and precise independent component analysis for high field fMRI time series tailored using prior information on spatiotemporal structure 1", *Human Brain Mapping*, vol. 15, no. 1, pp. 54-66.
- Tallon-Baudry, C., Bertrand, O., Delpuech, C., & Pernier, J. Oscillatory gamma-Band (30-70 Hz) Activity Induced by a Visual Search Task in Humans. *The Journal of Neuroscience* 17[2], 722-734. 1997.  
Ref Type: Journal (Full)
- Wakai, R. T., Strasburger, J. F., Li, Z., Deal, B. J., & Gotteiner, N. L. 2003, "Magnetocardiographic rhythm patterns at initiation and termination of fetal supraventricular tachycardia", *Circulation*, vol. 107, no. 2, pp. 307-312.